



TESIS - SS142501

**PREDIKSI NILAI EKSPOR JAWA TENGAH  
MENGUNAKAN PENDEKATAN  
*HIERARCHICAL TIME SERIES***

Dani Al Mahkya

1314201211

DOSEN PEMBIMBING

Dr. Brodjol Sutijo S.U., M.Si

Dr. Suhartono

PROGRAM STUDI MAGISTER

JURUSAN STATISTIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

INSTITUT TEKNOLOGI SEPULUH NOPEMBER

SURABAYA

2016



**THESES - SS142501**

**PREDICTION OF EXPORT VALUE IN  
CENTRAL JAVA USING HIERARCHICAL  
TIME SERIES APPROACH**

**Dani Al Mahkya**

**1314201211**

**SUPERVISOR**

**Dr. Brodjol Sutijo S.U., M.Si**

**Dr. Suhartono**

**MAGISTER PROGRAM**

**DEPARTMENT OF STATISTICS**

**FACULTY OF MATHEMATICS AND NATURAL SCIENCES**

**SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY**

**SURABAYA**

**2016**



**PREDIKSI NILAI EKSPOR JAWA TENGAH  
MENGUNAKAN PENDEKATAN *HIERARCHICAL TIME SERIES***

Tesis ini disusun untuk memenuhi salah satu syarat memperoleh gelar

**Magister Sains (M.Si)**

di

**Institut Teknologi Sepuluh Nopember**

Oleh:


**DANI AL MAHKYA**

**NRP. 1314201211**

**Tanggal Ujian : 19 Juli 2016**

**Periode Wisuda : September 2016**


**Disetujui oleh :**

  
**1. Dr. Brodjol Sutijo S.U., S.Si., M.Si.**  
**NIP. 196601251990021001**


**( Pembimbing I )**

  
**2. Dr. Suhartono**  
**NIP. 197109291995121001**

**( Pembimbing II )**

  
**3. Dr. Kartika Fithriasari, M.Si.**  
**NIP. 196912121993032002**

**( Penguji )**

  
**4. Dr. Ir. Setiawan, MS.**  
**NIP. 196010301987011001**

**( Penguji )**

  
**Direktur Program Pascasarjana,**

  
**Prof. Ir. Djauhar Manfaat, M.Sc. Ph.D.**

**NIP. 19601202 198701 1 001**

Halaman ini sengaja dikosongkan

# **PREDIKSI NILAI EKSPOR JAWA TENGAH MENGUNAKAN PENDEKATAN *HIERARCHICAL TIME SERIES***

Nama Mahasiswa : Dani Al Mahkya  
NRP : 1314201211  
Pembimbing : Dr. Brodjol Sutijo S.U., M.Si  
Dr. Suhartono

## **ABSTRAK**

Tujuan dari penelitian ini adalah mendapatkan pemodelan dan prediksi terbaik untuk nilai Ekspor Jawa Tengah menggunakan *Hierarchical Time Series*. Ekspor adalah suatu cara atau kegiatan untuk memasarkan barang yang diproduksi di dalam negeri dan dijual atau dipasarkan ke luar negeri. Nilai ekspor merupakan salah satu variabel injeksi dalam perekonomian suatu negara, artinya jika ekspor suatu negara meningkat maka perekonomian negara tersebut akan lebih meningkat lagi. Nilai Ekspor di Jawa Tengah dikelompokkan menjadi 21 komoditi dengan masing-masing komoditi mempunyai pola yang berbeda. Oleh karena itu, salah satu pendekatan deret waktu yang dapat digunakan adalah pendekatan hirarki. Pendekatan *Hierarchical Time Series* yang digunakan adalah *Bottom-up*, *Top-down* proporsi historis dan *Top-down* proporsi prediksi. Konsep dari pendekatan *Bottom-up* adalah dengan membangkitkan data hasil prediksi untuk masing-masing data deret waktu pada level bawah kemudian menjumlahkan untuk mendapatkan prediksi total atau prediksi level atas. Sedangkan konsep dari pendekatan *Top-down* proporsi historis adalah memecah hasil prediksi deret “Total” dan didistribusikan ke level bawah berdasarkan proporsi historis dari data tersebut. Dan konsep dari pendekatan *Top-down* proporsi prediksi adalah memecah hasil prediksi deret “Total” dan didistribusikan ke level bawah berdasarkan proporsi prediksi dari data tersebut. Metode prediksi yang digunakan adalah *Autoregressive Integrated Moving Average (ARIMA)*, *Radial Basis Function Neural Network (RBFNN)*, dan *Hybrid ARIMA-RBFNN*. Untuk pemilihan model terbaik digunakan *Median Absolute Percentage Error (MdAPE)*, *Symmetric Mean Absolute Percentage Error (sMAPE)*, dan *Symmetric Median Absolute Percentage Error (sMdAPE)*. Setelah dilakukan analisis, maka diperoleh kesimpulan bahwa untuk data Nilai Ekspor Jawa Tengah (level 0) pendekatan prediksi *Bottom-up* dengan pemodelan *Hybrid ARIMA-RBFNN* dapat digunakan untuk prediksi jangka panjang. Sedangkan untuk prediksi jangka pendek, pendekatan prediksi *Bottom-up* dengan pemodelan *RBFNN* dapat digunakan. Pada level 1 yaitu Nilai Ekspor Komoditas, pendekatan prediksi *independent* (tanpa hirarki) dengan pemodelan *ARIMA* dapat digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang.

Kata Kunci: *Hierarchical Time Series*, *ARIMA*, *RBFNN*, *Hybrid ARIMA-RBFNN*, *MdAPE*, *sMAPE*, *sMdAPE*.

Halaman ini sengaja dikosongkan

## **PREDICTION OF EXPORT VALUE IN CENTRAL JAVA USING HIERARCHICAL TIME SERIES APPROACH**

Name : Dani Al Mahkya  
NRP : 1314201211  
Supervisor : Dr. Brodjol Sutijo S.U., M.Si  
Dr. Suhartono

### **ABSTRACT**

The purpose of this study is getting the best modeling and predicting the export value of Central Java using a Hierarchical Time Series. Export is a method or activity to market goods produced domestically and sold or marketed abroad. The value of exports is one variable injection in the economy of a country, meaning that if a country's exports increases, the country's economy will increase even more. Export Value in Central Java are grouped into 21 commodities with each commodity has a different pattern. Therefore, one approach that can be used time series is a hierarchical approach. Hierarchical Approach Time Series is used Bottom-up, top-down historical proportions and Top-down prediction proportions. The concept of Bottom-up approach is to generate the prediction result data for each of the time series data at a lower level and then summing to obtain total predictions or predictions top level. While the concept of top-down approach is to break the historical proportions predicted outcome row "Total" and distributed to lower level by historical proportion of the data. And the concept of top-down approach is to break down the proportion of predicted outcome prediction series "Total" and distributed to lower levels based on the proportion of predictions from these data. Prediction methods used are Autoregressive Integrated Moving Average (ARIMA), Radial Basis Function Neural Network (RBFNN), and Hybrid ARIMA-RBFNN. For the selection of the best models used Median Absolute Percentage Error (MdAPE), Symmetric Mean Absolute Percentage Error (sMAPE) and Symmetric Median Absolute Percentage Error (sMdAPE). After analysis, it could be concluded that data of Export Value Central Java (level 0) Bottom-up approach to prediction with ARIMA modeling Hybrid-RBFNN can be used for long-term predictions. As for short-term prediction, prediction of a bottom-up approach to modeling RBFNN can be used. At level 1, namely Export Value of Commodities, predictive approach independent (non-hierarchical) with ARIMA modeling can be used to predict the short-term, medium and long term.

Keywords: Hierarchical Time Series, ARIMA, RBFNN, Hybrid ARIMA-RBFNN MdAPE, sMAPE, sMdAPE.



Halaman ini sengaja dikosongkan

## DAFTAR ISI

LEMBAR PENGESAHAN .....	i
ABSTRAK .....	iii
ABSTRACT .....	v
KATA PENGANTAR .....	vii
DAFTAR ISI .....	ix
DAFTAR GAMBAR .....	xi
DAFTAR TABEL .....	xiii
DAFTAR LAMPIRAN .....	xv
BAB I PENDAHULUAN .....	1
1.1. Latar Belakang .....	1
1.2. Perumusan Masalah .....	3
1.3. Tujuan .....	4
1.4. Manfaat .....	4
1.5. Batasan Penelitian .....	4
BAB II TINJAUAN PUSTAKA .....	5
2.1. Deret Waktu dan Prediksi .....	5
2.2. <i>Hierarchical Time Series (HTS)</i> .....	6
2.2.1. Pendekatan <i>Bottom-up</i> .....	6
2.2.2. Pendekatan <i>Top-down</i> Berdasarkan Proporsi Historis .....	7
2.2.3. Pendekatan <i>Top-down</i> Berdasarkan Proporsi Prediksi .....	8
2.3. <i>Autocorrelation Function</i> dan <i>Partial Autocorrelation Function</i> .....	9
2.3.1. <i>Autocorrelation Function (ACF)</i> .....	9
2.3.2. <i>Partial Autocorrelation Function (PACF)</i> .....	10
2.4. Model <i>Autoregressive Integrated Moving Average (ARIMA)</i> .....	11
2.4.1. Identifikasi Model ARIMA .....	12
2.4.2. Estimasi Parameter .....	14
2.4.3. Uji Diagnostik .....	15
2.5. Jaringan Syaraf Tiruan ( <i>Neural Network</i> ) .....	16
2.6. <i>Radial Basis Function Neural Network (RBFNN)</i> .....	16
2.6.1. Fungsi Aktivasi .....	17

2.6.2. <i>K-Means Cluster</i> .....	18
2.6.3. Tahapan Pembentukan Model RBFNN.....	19
2.7. <i>Hybrid Model</i> .....	20
2.8. Ukuran Ketepatan Prediksi.....	21
2.8.1. <i>Median Absolute Percentage Error (MdAPE)</i> .....	21
2.8.2. <i>Symmetric Mean Absolute Percentage Error (sMAPE)</i> .....	22
2.8.3. <i>Symmetric Median Absolute Percentage Error (sMdAPE)</i> .....	22
BAB III METODOLOGI .....	25
3.1. Sumber Data dan Variabel Penelitian.....	25
3.2. Metode Analisis.....	25
3.3. Diagram Alir Penelitian.....	28
BAB IV HASIL DAN PEMBAHASAN.....	33
4.1. Deskripsi Data .....	33
4.2. Pemodelan ARIMA .....	35
4.2.1. Pemodelan ARIMA Nilai Ekspor Total (Level 0).....	35
4.2.2. Pemodelan ARIMA Nilai Ekspor Komoditas (Level 1) .....	39
4.3. Pemodelan RBFNN .....	46
4.3.1. Pemodelan RBFNN Nilai Ekspor Total (level 0).....	46
4.3.2. Pemodelan RBFNN Nilai Ekspor Komoditas (level 1).....	47
4.4. Pemodelan Hybrid ARIMA-RBFNN .....	50
4.4.1. Pemodelan Hybrid ARIMA-RBFNN Nilai Ekspor Total (level 0).....	51
4.4.2. Pemodelan Hybrid ARIMA-RBFNN Nilai Ekspor Kom (level 1) .....	52
4.5. Pendekatan Hierarchical Time Series.....	56
4.6. Pemilihan Model Terbaik .....	57
4.7. Peramalan Nilai Ekspor Provinsi Jawa Tengah.....	60
BAB V KESIMPULAN .....	63
5.1. Kesimpulan.....	63
5.2. Saran .....	63
DAFTAR PUSTAKA.....	65
LAMPIRAN .....	69
BIODATA PENULIS.....	89

## DAFTAR GAMBAR

Gambar 2.1. Contoh deret waktu .....	5
Gambar 2.2. Struktur <i>Hierarchical Time Series</i> .....	6
Gambar 2.3. Arsitektur RBFNN .....	17
Gambar 3.1 Diagram Alir Penelitian .....	28
Gambar 3.2. Diagram Alir Penelitian (Lanjutan).....	29
Gambar 3.3. Diagram Alir Penelitian (Lanjutan).....	30
Gambar 3.4. Diagram Alir Penelitian (Lanjutan).....	31
Gambar 4.1. <i>Time Series Plot</i> Level 0 (Nilai Ekspor Total).....	34
Gambar 4.2. <i>Time Series Plot</i> Level 1 (Nilai Ekspor Komoditas).....	34
Gambar 4.3. <i>Time Series Plot</i> Ekspor Total .....	35
Gambar 4.4. Box-Cox Plot Ekspor Total .....	36
Gambar 4.5. ACF Ekspor Total.....	37
Gambar 4.6. PACF Ekspor Total.....	37
Gambar 4.7. <i>Time Series Plot</i> Komoditas 1 .....	39
Gambar 4.8. Box-Cox <i>Plot</i> Sebelum Transformasi Komoditas 1.....	40
Gambar 4.9. Box-Cox Plot Setelah Transformasi Komoditas 1 .....	40
Gambar 4.10. ACF Komoditas 1 ( <i>differencing lag 1</i> ).....	41
Gambar 4.11. PACF Komoditas 1 ( <i>differencing lag 1</i> ) .....	42
Gambar 4.12. ACF Komoditas 1 .....	47
Gambar 4.13. PACF Komoditas 1 .....	48
Gambar 4.14. Pembagian data <i>Rolling Forecast Origin</i> .....	57
Gambar 4.15. Proses <i>Rolling Forecast Origin</i> pada $h=1$ .....	57
Gambar 4.16. Keakuratan Prediksi Pada Level 0 dengan sMAPE.....	58
Gambar 4.17. Keakuratan Prediksi Pada Level 1 dengan sMAPE.....	58
Gambar 4.18. Peramalan Nilai Ekspor Jawa Tengah 12 periode ke depan.....	60
Gambar 4.19. Peramalan Nilai Ekspor Jawa Tengah Komoditas 7 untuk 12 periode ke depan.....	61

Halaman ini sengaja dikosongkan

## DAFTAR TABEL

Tabel 2.1. Karakteristik ACF dan PACF .....	13
Tabel 2.2. Fungsi <i>Radial Basis</i> .....	17
Tabel 2.3. Penelitian Sebelumnya .....	23
Tabel 3.1. Variabel Penelitian .....	27
Tabel 4.1. Statistika deskriptif data nilai ekspor Jawa Tengah .....	33
Tabel 4.2. Estimasi Parameter Ekspor Total .....	38
Tabel 4.3. Pengujian Diagnostik Ekspor Total .....	38
Tabel 4.4. Estimasi Parameter Komoditas 1 .....	42
Tabel 4.5. Pengujian Diagnostik Komoditas 1 .....	43
Tabel 4.6. Hasil Keseluruhan Pemodelan ARIMA .....	44
Tabel 4.7. Pemilihan Model Terbaik Ekspor Total .....	47
Tabel 4.8 (b). Pemilihan Model Terbaik Komoditas 1 .....	48
Tabel 4.8 (b). Pemilihan Model Terbaik Komoditas 1 .....	49
Tabel 4.9. Hasil Keseluruhan Pemodelan RBFNN .....	49
Tabel 4.10. Pemilihan Model Terbaik Ekspor Total .....	51
Tabel 4.11. Pemilihan Model Terbaik Komoditas 1 .....	53
Tabel 4.12. Hasil Keseluruhan Pemodelan <i>Hybrid</i> ARIMA-RBFNN .....	54
Tabel 4.13. Pemodelan <i>Hierarchical Time Series</i> .....	56
Tabel 4.14. Pemilihan Model dengan Salah Satu Kriteria Keباikan Model yang digunakan yaitu sMAPE .....	59
Tabel 4.15. Peramalan Nilai Ekspor Total (level 1) dan Komoditas 7 (Level 1) .	61

Halaman ini sengaja dikosongkan

## DAFTAR LAMPIRAN

Lampiran 1. Data Ekspor .....	69
Lampiran 2. Time Series Plot Masing-masing Nilai Ekspor .....	70
Lampiran 3. Sintaks Pemodelan ARIMA (Komoditas 1) $h=12$ .....	80
Lampiran 4. Sintaks Pemodelan RBFNN (Komoditas 1) $h=12$ .....	81
Lampiran 5. Sintaks Pemodelan Hybrid ARIMA-RBFNN (Komoditas 1) $h=12$ .....	82
Lampiran 6. Hasil Keseluruhan Pemilihan Model .....	83



Halaman ini sengaja dikosongkan

## **BAB 1**

### **PENDAHULUAN**

#### **1.1. Latar Belakang**

Ekspor adalah suatu cara atau kegiatan untuk memasarkan barang yang diproduksi di dalam negeri dan dijual atau dipasarkan ke luar negeri. Jika suatu negara membuka perdagangan internasional dan menjadi pengekspor suatu barang, maka produsen domestik barang tersebut akan diuntungkan dan konsumen domestik barang tersebut akan dirugikan. Nilai ekspor merupakan salah satu variabel injeksi dalam perekonomian suatu negara, artinya jika ekspor suatu negara meningkat maka perekonomian negara tersebut akan lebih meningkat lagi (Chalid, 2013).

Pertumbuhan ekonomi Provinsi Jawa Tengah setelah tahun 1999 selalu tumbuh positif, ini juga ditentukan oleh beberapa indikator yang cenderung meningkat. Sektor luar negeri memegang peranan penting dalam perekonomian Provinsi Jawa Tengah. Selama periode 1997 sampai 2010 nilai ekspor dan impor mengalami kenaikan. Dengan demikian perekonomian Provinsi Jawa Tengah dapat dikatakan sebagai perekonomian terbuka (Rejekiingsih, 2012). Dengan kata lain dapat dikatakan bahwa sektor ekspor di Provinsi Jawa Tengah merupakan sebuah tonggak yang sangat menjanjikan untuk memajukan perekonomian Provinsi Jawa Tengah. Selain itu peranan suatu daerah dalam kancah sektor ekspor Nasional sangatlah tinggi, tingkat daya saing suatu Negara sesungguhnya dipengaruhi oleh keunggulan daya saing yang berkelanjutan. Terutama dalam rangka menghadapi persaingan global yang lama menjadi sedemikian ketat (Rejekiingsih, 2012).

Setiap tahun ekspor di Provinsi Jawa Tengah terus mengalami kenaikan, hal ini menandakan bahwa perekonomian di Jawa Tengah akan terus berkembang dan tentunya akan berdampak pada sektor ekspor Indonesia pada umumnya. Memprediksi nilai ekspor khususnya di Provinsi Jawa Tengah tentunya sangat dibutuhkan untuk pengembangan kebijakan. Karena dengan sebuah nilai perkiraan pada masa yang akan datang, akan membantu dalam perencanaan yang matang kedepannya. Oleh karena itu dibutuhkan sebuah

model prediksi yang tepat untuk mengetahui apakah ekspor di Provinsi Jawa Tengah akan terus meningkat atau justru akan turun. Studi tentang prediksi nilai ekspor di Provinsi Jawa Tengah akan sangat menarik untuk dibahas karena dari tahun 2009 sampai 2015 nilai ekspor cenderung naik dan tidak mengalami penurunan yang signifikan. Hal ini tentu memberikan dampak yang sangat besar. Maka dari itu, perlu adanya sebuah model prediksi nilai ekspor di Provinsi Jawa Tengah yang dapat digunakan pihak-pihak terkait dalam pembuatan kebijakan serta pengambilan keputusan.

Penelitian tentang nilai ekspor pernah dilakukan sebelumnya, seperti pada tahun 2011, Chalid melakukan penelitian tentang peranan ekspor dalam perekonomian Indonesia. Rejekiingsih pada tahun 2012 meneliti tentang konsentrasi ekspor di Provinsi Jawa Tengah. Pada tahun 2013, Tambun menganalisis tentang struktur dan kinerja ekspor komoditas pertanian pasca krisis ekonomi di Sulawesi utara. Mahkya (2014) memprediksi nilai ekspor Provinsi Jawa Tengah dengan asumsi bahwa nilai ekspor Provinsi Jawa Tengah periode ke- $t$  dipengaruhi oleh nilai ekspor periode ke- $t-1$ .

Data nilai ekspor Jawa Tengah merupakan data hirarki atau data yang mempunyai tingkatan. Nilai ekspor total sebagai data hirarki level 0 atau tingkat atas sedangkan nilai ekspor per komoditi sebanyak 21 komoditi sebagai data hirarki level 1 atau tingkat bawah. Oleh karena itu, pada penelitian ini akan diprediksi nilai ekspor Jawa Tengah dengan mempertimbangkan struktur hirarki menggunakan pendekatan *Hierarchical Time Series*. Pendekatan *Hierarchical Time Series* mensyaratkan data yang digunakan mempunyai struktur hirarki yang lengkap pada masing-masing level. Dengan kata lain jika salah satu level pada struktur hirarki hilang, maka data tersebut tidak dapat dimodelkan dengan pendekatan *Hierarchical Time Series*. Pada penelitian ini data hirarki level 1 yang digunakan adalah sebanyak 19 *series* karena terdapat beberapa *series* yang tidak dapat dimodelkan. Data nilai ekspor Provinsi Jawa Tengah untuk masing-masing komoditi mempunyai pola yang berbeda-beda. Oleh karena itu digunakan 3 pendekatan prediksi yaitu *Autoregressive Integrated Moving Average (ARIMA)*, *Radial Basis Function Neural Network (RBFNN)*, dan *Hybrid ARIMA-RBFNN* yang diharapkan dapat menangkap

fenomena-fenomena yang terjadi pada pola data. Pendekatan *Hierarchical Time Series* pernah dilakukan oleh Athanasopoulos, *et al.* (2007) untuk memprediksi banyaknya kunjungan turis domestik di Australia. Pada tahun 2011, Utari dan Suhartono memprediksi permintaan BBM di PT. Pertamina Region V dengan pendekatan *Hierarchical Time Series*. Shang *et al.* pada tahun 2013 menggunakan pendekatan *Hierarchical Time Series* untuk memprediksi banyaknya kematian bayi di Australia.

Pemilihan kriteria kebaikan model merupakan salah satu hal yang vital dalam aspek prediksi. *Mean Absolute Percentage Error (MAPE)* merupakan salah satu kriteria kebaikan model yang sering digunakan. Namun nilai MAPE akan bermasalah jika data deret waktu mempunyai nilai mendekati nol atau sama dengan nol. Oleh karena itu, pemilihan model terbaik pada penelitian ini menggunakan *Median Absolute Percentage Error (MdAPE)*, *Symmetric Mean Absolute Percentage Error (sMAPE)*, dan *Symmetric Median Absolute Percentage Error (sMdAPE)*. Amstrong, *et al.* (1992) menggunakan MdAPE sebagai kriteria kebaikan model untuk metode prediksi. Pada tahun 2000, Makridakis, *et al.* membahas sMAPE pada jurnal The M3-Competition. Sedangkan Hyndman, *et al.* (2005) membahas sMdAPE pada jurnal Another Look at Measures of Forecast Accuracy.

## **1.2. Perumusan Masalah**

Berdasarkan uraian di atas maka diperoleh beberapa permasalahan sebagai berikut :

1. Bagaimana hasil pemodelan Nilai Ekspor Jawa Tengah dengan pendekatan *Hierarchical Time Series*?
2. Bagaimana cara menentukan keakuratan prediksi Nilai Ekspor Jawa Tengah dengan pendekatan *Hierarchical Time Series*?
3. Bagaimana hasil prediksi nilai ekspor Provinsi Jawa Tengah untuk periode 12 bulan ke depan?

### 1.3. Tujuan

Berdasarkan rumusan masalah diatas, terdapat beberapa tujuan yang ingin dicapai dari penelitian ini adalah sebagai berikut :

1. Mendapatkan hasil pemodelan terbaik dengan pendekatan *Hierarchical Time Series*.
2. Mendapatkan keakuratan pemodelan terbaik dengan kriteria MdAPE, sMAPE dan sMdAPE.
3. Mendapatkan hasil prediksi nilai ekspor Provinsi Jawa Tengah untuk periode 12 bulan ke depan menggunakan pendekatan *Hierarchical Time Series*.

### 1.4. Manfaat

Manfaat yang diperoleh dari hasil penelitian ini adalah dapat mengetahui prediksi nilai ekspor Provinsi Jawa Tengah dan nilai keakuratannya untuk beberapa periode ke depan dengan menggunakan *Hierarchical Time Series*.

### 1.5. Batasan Penelitian


Batasan pada penelitian ini adalah nilai total ekspor provinsi Jawa Tengah, dan 19 nilai ekspor komoditi di Provinsi Jawa Tengah dari periode Januari 2007 sampai Desember 2015. Pada *Hierarchical Time Series* digunakan pendekatan *Bottom-up*, *Top-down* Proporsi Historis (Januari-Desember 2014) dan *Top-down* Proporsi Prediksi. Untuk metode *Radial Basis Function Neural Network* digunakan fungsi aktivasi *Gaussian*.

## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Deret Waktu dan Prediksi

Menurut Wei (2006), deret waktu adalah urutan dari observasi-observasi. Biasanya diurutkan berdasarkan waktu, pada saat tertentu beberapa diurutkan berdasarkan interval waktu. Beberapa contoh deret waktu ditampilkan pada Gambar 2.1.




Gambar 2.1. Contoh deret waktu

Salah satu hal penting dalam membangun sebuah model deret waktu adalah dapat memprediksi nilai deret waktu untuk waktu yang akan datang (Cryer *et al.*, 2008: 191). Dengan memprediksi nilai deret waktu yang akan datang, dapat diperoleh tahapan baru dalam sebuah analisis, yaitu tahapan pengambilan kebijakan. Kebijakan dalam hal ekonomi, politik maupun sosial.

## 2.2. Hierarchical Time Series (HTS)

Menurut Shang *et al.* (2013) *Hierarchical Time Series* mempunyai struktur sebagai berikut :



Gambar 2.2. Struktur *Hierarchical Time Series*

Berdasarkan Gambar 2.2 variabel “Total” adalah data deret waktu level 0 yang merupakan jumlahan dari variabel-variabel deret waktu pada level 1. Begitu juga untuk data deret waktu level 1 yang merupakan jumlahan dari variabel-variabel level 2 dan begitu seterusnya hingga level ke  $K$ . Pada umumnya notasi untuk pendekatan HTS, digunakan  $Y_{i,t}$  yang terdiri dari semua pengamatan level ke  $i$  dan waktu ke  $t$ . Semua pengamatan pada waktu ke  $t$  dinotasikan dengan  $Y_t = [Y_t, Y'_{1,t}, \dots, Y'_{K,t}]'$  merupakan vector kolom (Athanasopoulos *et al.*, 2007:6), sehingga dapat dituliskan sebagai berikut :

$$Y_t = SY_{K,t} \quad (2.1)$$

dimana  $S$  adalah penjumlahan matriks orde  $m \times m_K$  yang merupakan jumlahan dari semua data deret waktu level bawah.

### 2.2.1. Pendekatan *Bottom-up*

Menurut Shang *et al.* (2013) konsep dari pendekatan *Bottom-up* adalah dengan membangkitkan data hasil prediksi untuk masing-masing data deret waktu pada level bawah kemudian menjumlahkan untuk mendapatkan prediksi total atau prediksi level atas. Ilustrasi pendekatan *Bottom-up* dapat dilihat pada Gambar 2.2 dan berikut adalah tahapan-tahapannya:

- Membangkitkan hasil prediksi pada level bawah seperti  $\hat{Y}_{AA,t}, \hat{Y}_{AB,t}, \hat{Y}_{BA,t}$ , dan  $\hat{Y}_{BB,t}$ .
- Menjumlahkan hasil prediksi level bawah untuk mendapatkan nilai prediksi level atas.

$$\hat{Y}_{At} = \hat{Y}_{AA,t} + \hat{Y}_{AB,t}$$

$$\hat{Y}_{Bt} = \hat{Y}_{BA,t} + \hat{Y}_{BB,t}$$

$$\hat{Y}_t = \hat{Y}_{At} + \hat{Y}_{Bt}$$

- Merevisi hasil prediksi dengan membandingkan nilai aktual untuk tiap level.

$$\hat{Y}_{AA,t} = Y_{AA,t}$$

$$\hat{Y}_{AB,t} = Y_{AB,t}$$

$$\hat{Y}_{BA,t} = Y_{BA,t}$$

$$\hat{Y}_{BB,t} = Y_{BB,t}$$

$$\hat{Y}_{At} = Y_{At}$$

$$\hat{Y}_{Bt} = Y_{Bt}$$

$$\hat{Y}_t = Y_t$$

Kelebihan dari pendekatan *Bottom-up* adalah tidak ada informasi yang hilang selama proses penggabungan untuk tiap level. Namun pada sisi lain, pendekatan *Bottom-up* mungkin akan menjadi tidak akurat untuk memprediksi jika terdapat data *missing* ataupun *noisy* pada level bawah (Shang *et al.*, 2013).

### 2.2.2. Pendekatan *Top-down* Berdasarkan Proporsi Historis

Menurut Athanasopoulos *et al.* (2007), bentuk dari pendekatan *Top-down* berdasarkan proporsi historis adalah memecah hasil prediksi deret “Total” dan didistribusikan ke level bawah berdasarkan proporsi historis dari data tersebut.



Pada pendekatan *Top-down* berdasarkan proporsi historis terdapat dua cara dalam menentukan proporsi yang digunakan yaitu sebagai berikut (Athanasopoulos *et al.*, 2007:8):

$$p_j = \sum_{t=1}^n \frac{Y_{jt}}{Y_t} / n \quad (2.2)$$

dengan  $j = 1, \dots, m_k$ . Untuk setiap proporsi  $p_j$  menggambarkan nilai rata-rata dari proporsi historis level bawah deret  $\{Y_{j,t}\}$  pada waktu  $t = 1, \dots, n$ .

Cara yang kedua adalah sebagai berikut:

$$p_j = \sum_{t=1}^n \frac{Y_{jt}}{n} / \sum_{t=1}^n \frac{Y_t}{n} \quad (2.3)$$

dengan  $j = 1, \dots, m_k$ . Untuk setiap proporsi  $p_j$  menangkap nilai rata-rata historis level bawah deret  $\{Y_{j,t}\}$  pada waktu  $t = 1, \dots, n$ . Pendekatan *Top-down* berdasarkan proporsi historis sangat cocok digunakan untuk data dengan jumlah rendah. Di sisi lain, pada pendekatan ini akan banyak terjadi kehilangan informasi selama proses penggabungan maupun pemisahan (Athanasopoulos *et al.*, 2007). Terdapat beberapa tahapan dalam pendekatan *Top-down* berdasarkan proporsi historis yaitu sebagai berikut:

- Menghitung proporsi antara level atas dan level bawah berdasarkan data historis.
- Menghitung nilai prediksi level atas.
- Memecah hasil prediksi level atas berdasarkan proporsi historis.

### 2.2.3. Pendekatan *Top-down* Berdasarkan Proporsi Prediksi

Menurut Athanasopoulos *et al.* (2007), untuk meningkatkan ketepatan prediksi dari proporsi historis dan gangguan alami dari data dapat digunakan pemisahan berdasarkan proporsi hasil prediksi. Namun pendekatan *Top-down* berdasarkan proporsi prediksi tidak dapat menghasilkan prediksi yang *unbiased* (Athanasopoulos *et al.*, (2007).

Pendekatan *Top-down* berdasarkan proporsi prediksi mempunyai persamaan sebagai berikut (Athanasopoulos *et al.*, 2007:8):

$$p_j = \prod_{t=0}^{K-1} \frac{\hat{Y}_{jn}^{(i)}(h)}{\sum (\hat{Y}_{jn}^{(i+1)}(h))} \quad (2.4)$$

dimana  $j = 1, \dots, m_k$ , dengan  $\hat{Y}_{j,n}^{(i)}(h)$  hasil prediksi  $h$  tahap kedepan dan  $\sum (\hat{Y}_{jn}^{(i+1)}(h))$  adalah hasil penjumlahan prediksi  $h$  tahap kedepan.

Terdapat beberapa tahapan dalam pendekatan *Top-down* berdasarkan proporsi prediksi yaitu sebagai berikut:

- Menghitung nilai prediksi level atas dan bawah.
- Menghitung proporsi antara level atas dan level bawah berdasarkan nilai prediksi.
- Memecah hasil prediksi level atas menjadi prediksi level bawah berdasarkan proporsi prediksi yang telah diperoleh.

### 2.3. Autocorrelation Function dan Partial Autocorrelation Function

#### 2.3.1. Autocorrelation Function (ACF)

Menurut Wei (2006) untuk proses stasioner  $[Z_t]$ , mempunyai rata-rata  $E(Z_t) = \mu$  dan varians  $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$  bernilai konstan dan kovarians  $Cov(Z_t - Z_s)$  fungsi yang hanya berasal dari perbedaan waktu  $|t - s|$ . Oleh karena itu kovarian antara  $Z_t$  dan  $Z_{t+k}$  dapat ditulis sebagai berikut:

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.5)$$

dan korelasi antara  $Z_t$  dan  $Z_{t+k}$  dapat ditulis sebagai berikut:

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.6)$$

dengan

$\rho_k$  : autokorelasi pada lag k

$\mu$  : rata-rata

$\gamma_k$  : autokovariansi pada lag k

$t$  : waktu pengamatan,  $t = 1, 2, 3, \dots$

dimana  $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$ . Sebagai fungsi dari  $k$ ,  $\gamma_k$  disebut *autocovariances function* dan  $\rho_k$  disebut *autocorrelation function* (ACF). Jadi, rumus ACF pada lag- $k$  dituliskan sebagai berikut (Wei, 2006: 20):

$$\hat{\rho}_k = r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad k = 0, 1, 2, \dots \quad (2.7)$$

dengan

$r_k$  = koefisien autokorelasi pada lag- $k$

$\bar{Z}$  = rata-rata observasi  $\{Z_t\}$

$Z_t$  = observasi pada waktu ke- $t$

$Z_{t+k}$  = observasi pada waktu ke- $t+k$

### 2.3.2. Partial Autocorrelation Function (PACF)

Pada *autocorrelation* antara  $Z_t$  dan  $Z_{t+k}$ , ingin diselidiki korelasi antara  $Z_t$  dan  $Z_{t+k}$  setelah dihilangkannya pengaruh hubungan linier dari  $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$  terhadap  $Z_{t+k}$ . Pada kasus tersebut PACF dapat digunakan untuk menyelesaikannya (Wei, 2006: 11).

Menurut Montgomery *et al.* (2008) PACF dinotasikan  $\phi_{kk}$  dengan rumus sebagai berikut:

$$\phi_{kk} = \frac{|\rho_k|}{|P_k|} \quad (2.8)$$

Rumus ini didasari dari persamaan Yule-Walker,

$$P_k \phi_{kk} = \rho_k \quad (2.9)$$

dengan

$$\rho_k = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \text{ dan } \phi_{kk} = \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} \quad (2.10)$$

dan

$$P_k = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & \cdots & \rho_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \quad (2.11)$$

untuk  $k = 1, 2, \dots$  diperoleh

$$\phi_{kk} = \frac{|\rho_1|}{|P_1|} = \frac{|\rho_1|}{1} = \rho_1 \quad (2.12)$$

$$\phi_{22} = \frac{|\rho_2|}{|P_2|} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \quad (2.13)$$

dan seterusnya sampai  $\phi_{kk}$ .

#### 2.4. Model Autoregressive Integrated Moving Average (ARIMA)

Menurut Montgomery *et al.* (2008) terdapat 3 tahapan yang digunakan untuk membangun sebuah model ARIMA. Tiga tahapan tersebut adalah sebagai berikut:

- Model ARIMA sementara diidentifikasi dengan menganalisis data masa lampau.
- Mengestimasi parameter model yang tidak diketahui.
- Melakukan pengecekan diagnostik *residual* yang dihasilkan untuk menentukan kecukupan model atau mengindikasikan perlu tidaknya dilakukan perbaikan.

Setelah tahapan-tahapan tersebut selesai dilakukan, maka diperoleh model ARIMA terbaik.

### 2.4.1. Identifikasi Model ARIMA

Mengidentifikasi sebuah model harus dimulai dengan persiapan dalam memahami darimana data berasal dan bagaimana data dikumpulkan. Memperhatikan karakteristik dan frekuensi pengambilan data seringkali memberikan informasi penting dalam menyiapkan tahapan identifikasi model. Menurut Montgomery *et al.* (2008) merekomendasikan kecukupan data untuk analisis deret waktu adalah 50 observasi atau lebih. Setelah banyaknya observasi terpenuhi, langkah selanjutnya adalah membuat plot deret waktu. Plot deret waktu tersebut dapat digunakan dalam menduga kestasioneran data. Menurut Wei (2006) dalam menguji kestasionertisan data, digunakan hipotesis  $H_0 : \phi = 1$  dan  $H_1 : \phi < 1$  dengan statistik hitung

$$T = \frac{(\hat{\phi} - 1)}{S_{\hat{\phi}}} \quad (2.14)$$

dimana

$$\hat{\phi} = \frac{\sum_{t=1}^n Z_{t-1} Z_t}{\sum_{t=1}^n Z_{t-1}^2} \quad (2.15)$$

serta digunakan proses *differencing* dalam menanggulangi ketidakstasioneritasan data dalam *mean*. Sedangkan untuk mengatasi ketidakstasionerritasan data dalam varians, digunakan transformasi Box-Cox dengan persamaan sebagai berikut (Wei, 2006: 85):

$$T(Z_t) = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln Z_t, & \lambda = 0 \end{cases} \quad (2.16)$$

Menurut Wei (2006) untuk ilustrasi dalam pengidentifikasian sebuah model, digunakan model ARIMA( $p, d, q$ ) dengan model sebagai berikut:

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d Z_t = \theta_0 + (1 - \theta_1 B - \dots - \theta_q B^q) a_t \quad (2.17)$$

Terdapat tahapan-tahapan dalam mengidentifikasi sebuah model deret waktu (Wei, 2006:108) yaitu:

- Membuat plot deret waktu dari data dan memilih transformasi yang tepat. Dengan plot deret waktu, biasanya akan diperoleh beberapa informasi seperti pola tren, musiman dan pola ketidak stasioneran data.
- Menghitung dan menguji ACF dan PACF dari data asli untuk mengetahui apakah dibutuhkan *differencing* atau tidak dalam menstasionerkan data. Jika ACF menurun sangat lambat dan PACF terpotong setelah *lag* 1 maka mengindikasikan perlu dilakukannya *differencing*. Dapat dilakukan *differencing* pertama  $(1-B)Z_t$  untuk kasus tersebut. Secara umum untuk menstasionerkan data deret waktu dapat digunakan *high-order differencing*  $(1-B)^d Z_t$  untuk  $d > 1$ . Jika  $(1-B)^d Z_t$  stasioner maka  $(1-B)^{d+i} Z_t$  untuk  $i = 1, 2, \dots$  akan menghasilkan data yang stasioner.
- Menghitung dan menguji ACF dan PACF dari data yang telah mengalami proses *transformation* maupun *differencing* untuk mengidentifikasi orde  $p$  dan  $q$ , dimana  $p$  adalah orde tertinggi pada polinomial *autoregressive*  $(1-\phi_1 B - \dots - \phi_p B^p)$  dan  $q$  adalah orde tertinggi pada polinomial *moving average*  $(1-\theta_1 B - \dots - \theta_q B^q)$ . Karakteristik dari teori ACF dan PACF untuk proses yang stasioner dijelaskan pada tabel berikut (Wei, 2006: 109):

Tabel 2.1. Karakteristik ACF dan PACF

Proses	ACF	PACF
AR( $p$ )	Menurun secara eksponensial atau berpola gelombang sinus	Terpotong pada <i>lag</i> ke $p$
MA( $q$ )	Terpotong pada <i>lag</i> ke $p$	Menurun secara eksponensial atau berpola gelombang sinus
ARMA( $p, q$ )	Terpotong setelah <i>lag</i> ( $q - p$ )	Terpotong setelah <i>lag</i> ( $p - q$ )

### 2.4.2. Estimasi Parameter

Salah satu metode untuk estimasi model derat waktu adalah *Conditional Maximum Likelihood Estimation*. Untuk model umum ARMA ( $p, q$ ):

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.18)$$

dimana  $\dot{Z}_t = Z_t - \mu$  dan  $[a_t]$  adalah i.i.d.  $N(0, \sigma_a^2)$  *white noise*, fungsi densitas bersama dari  $\mathbf{a} = (a_1, a_2, \dots, a_n)'$  diberikan pada persamaan:

$$P(\mathbf{a} | \phi, \mu, \theta, \sigma_a^2) = (2\pi\sigma_a^2)^{-\frac{n}{2}} \exp \left[ -\frac{1}{2\sigma_a^2} \sum_{i=1}^n a_i^2 \right] \quad (2.19)$$

Persamaan (2.18) ditulis ulang menjadi:

$$a_t = \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} + \dot{Z}_t - \phi_1 \dot{Z}_{t-1} - \dots - \phi_p \dot{Z}_{t-p} \quad (2.20)$$

Diketahui  $\mathbf{Z} = (Z_1, Z_2, \dots, Z_n)'$  dan diasumsikan kondisi awal  $\mathbf{Z}_* = (Z_{1-p}, \dots, Z_{-1}, Z_0)'$  serta  $\mathbf{a}_* = (a_{1-q}, \dots, a_{-1}, a_0)'$ , maka fungsi *conditional log-likelihood* untuk parameter  $(\phi, \mu, \theta, \sigma_a^2)$  adalah sebagai berikut:

$$\ln L_*(\phi, \mu, \theta, \sigma_a^2) = -\frac{n}{2} \ln 2\pi\sigma_a^2 - \frac{S_*(\phi, \mu, \theta)}{2\sigma_a^2} \quad (2.21)$$

dimana

$$S_*(\phi, \mu, \theta) = \sum_{t=1}^n a_t^2(\phi, \mu, \theta | Z_*, \mathbf{a}_*, Z) \quad (2.22)$$

adalah fungsi jumlah kuadrat kondisional. Jumlah dari  $\hat{\phi}$ ,  $\hat{\mu}$ , dan  $\hat{\theta}$  yang memaksimumkan persamaan (2.21) disebut *Conditional Maximum Likelihood Estimator*. Karena  $\ln L_*(\phi, \mu, \theta, \sigma_a^2)$  menggunakan data hanya pada  $S_*(\phi, \mu, \theta)$ , maka estimator tersebut sama dengan estimasi *Conditional Least Square (CLS)* didasari dari aspek meminimumkan fungsi *Conditional Sum of Square*  $S_*(\phi, \mu, \theta)$  yang tidak mengandung parameter  $\sigma_a^2$  (Wei, 2006:139).

### 2.4.3. Uji Diagnostik

Setelah tahapan estimasi parameter, selanjutnya adalah tahap pengujian asumsi. Asumsi dasar yang digunakan adalah  $\{a_t\}$  merupakan deret yang *White Noise* dan berdistribusi Normal. Deret *White Noise* yaitu deret waktu yang tidak berkorelasi dengan *mean* bernilai nol dan *variance* bernilai konstan (Wei, 2006:152). Untuk menguji apakah deret  $a_t$  merupakan deret yang *White Noise* atau tidak digunakan *Ljung-Box Test* dengan hipotesis

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$$

dan statistik hitung

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.23)$$

dimana

$k$  = lag ke k

$\hat{\rho}_k$  = autokorelasi pada lag ke k

Dalam kasus nyata kadangkala asumsi normalitas tidak terpenuhi dikarenakan adanya *outlier*. Deteksi *outlier* pertama kali diperkenalkan oleh Fox (1972) dalam (Wei, 2006). Secara umum model *outlier* dirumuskan sebagai berikut:

$$Y_t = \sum_{j=1}^k \omega_j v_j(B) I_t^{(T)} + X_t \quad (2.24)$$

dengan

$$X_t = \frac{\theta(B)}{\phi(B)} a_t$$

$$v_j(B) = 1 \text{ untuk AO}$$

$$v_j(B) = \frac{1}{(1-B)} \text{ untuk LS}$$

Pada penelitian ini *outlier* dibagi menjadi dua yaitu *Additive Outlier (AO)* dan *Level Shift (LS)*. AO merupakan *outlier* yang



memberikan pengaruh hanya pada waktu ke- $T$ . Sedangkan LS memberikan pengaruh pada waktu ke- $T$  dan efeknya bersifat tetap. dengan model AO dan LS sebagai berikut (Wei, 2006) :

$$Z_t = X_t + \omega I_{A,t}^{(T)} \quad \text{dengan} \quad I_{A,t}^{(T)} = \begin{cases} 1, & t = T \\ 0, & t \neq T \end{cases} \quad (2.25)$$

$$Z_t = X_t + \omega I_{S,t}^{(T)} \quad \text{dengan} \quad I_{S,t}^{(T)} = \begin{cases} 1, & t \geq T \\ 0, & t < T \end{cases} \quad (2.26)$$

## 2.5. Jaringan Syaraf Tiruan (*Neural Network*)

Menurut Smith *et al.*(2002) Jaringan Syaraf Tiruan adalah salah satu alat komputasi sederhana untuk menguji sebuah data dan mengembangkan sebuah model yang digunakan untuk mengidentifikasi pola-pola atau struktur yang menarik pada sebuah data. Data yang digunakan untuk mengembangkan model tersebut adalah data *Training*. Ketika Jaringan Syaraf Tiruan mengolah dan mempelajari pola pada data *Training* yang digunakan. Maka hasil dari mempelajari pola tersebut dapat digunakan untuk data yang baru.


Jaringan Sayaraf Tiruan dapat digunakan untuk beberapa hal sebagai berikut (Smith *et al.*,2002:2):

- Mempelajari suatu data untuk memprediksi masa yang akan datang berdasarkan pola-pola masa lampau yang telah diamati pada data *Training*.
- Mempelajari suatu data untuk menggolongkan data kedalam kelompok-kelompok yang telah ditetepkan berdasarkan karakteristik yang telah diamati pada data *Training*.
- Mempelajari suatu data untuk mengelompokkan data kedalam kelompok-kelompok berdasarkan kesamaan karakteristik pada data *Training*.

## 2.6. Radial Basis Function Neural Network (*RBFNN*)

RBFNN muncul sebagai salah satu tipe jaringan syaraf tiruan sekitar tahun 80-an. Konstruksi dari RBFNN mengandung tiga lapisan berbeda. Lapisan pertama yaitu *Input Layer* berasal dari unit-unit sensor. Lapisan kedua adalah *Hidden Layer* dengan RBF dimensi tinggi yang bertujuan untuk

memproses *Perceptron* lapisan banyak. Lapisan ketiga yaitu *Output Layer* yang menyediakan respon dari jaringan ke pola aktivasi yang diterapkan pada *Input Layer* (Zeng *et al.*,2010:257). Menurut Hanrahan (2011) RBFNN mempunyai arsitektur sebagai berikut:



Gambar 2.3. Arsitektur RBFNN

### 2.6.1. Fungsi Aktivasi

Menurut Sturgill (2009), terdapat beberapa fungsi *Radial Basis*. Beberapa fungsi tersebut tertera pada tabel berikut:

Tabel 2.2. Fungsi *Radial Basis*

Nama Fungsi	Fungsi ( $\phi(r), r \geq 0$ )
<i>Gaussian</i>	$e^{-(\varepsilon r)^2}$
<i>Generalized Multiquadratic</i>	$(1 + (\varepsilon r)^2)^\beta$
<i>Invers Multiquadratic</i>	$\frac{1}{\sqrt{1 + (\varepsilon r)^2}}$
<i>Invers Quadratic</i>	$\frac{1}{1 + (\varepsilon r)^2}$
<i>Multiquadratic</i>	$\sqrt{1 + (\varepsilon r)^2}$
<i>Cubic</i>	$r^3$
<i>Linier</i>	$r^2$
<i>Monomial</i>	$r^{2k-1}$
<i>Thin Plate Spline</i>	$r^2 \log(r)$

Menurut McNelis (2005), RBFNN menggunakan fungsi *Radial Basis* sebagai fungsi aktivasi. *Output* yang dihasilkan model RBFNN merupakan kombinasi linier dari bobot  $\{w_j\}_{j=1}^m$  dengan fungsi aktivasi  $\phi_j(x)$  dan dirumuskan sebagai berikut (Orr, 1996:11):

$$y = \sum_{j=1}^m w_j \phi_j(x) \quad (2.27)$$

dengan:

- $m$  = banyaknya fungsi aktivasi
- $w_j$  = bobot *output* ke- $j$
- $\phi_j(x)$  = fungsi aktivasi *hidden layer* ke- $j$
- $\mathbf{x}$  =  $[x_1, x_2, \dots, x_p]$  vektor *input*

Berdasarkan fungsi *Radial Basis Gaussian*, maka diperoleh persamaan sebagai berikut:

$$\phi_j(x) = \exp\left(-\frac{\|x - \mu\|^2}{2\sigma_j^2}\right) \quad (2.28)$$

$$= \exp\left[-\frac{1}{2}\left\{\left(\frac{x_1 - \mu_1}{\sigma_1}\right)^2 + \left(\frac{x_i - \mu_j}{\sigma_j}\right)^2 + \dots + \left(\frac{x_p - \mu_m}{\sigma_m}\right)^2\right\}\right] \quad (2.29)$$

dengan:

- $x_i$  = *input* ke- $i$ ,  $i=1,2,\dots,p$
- $\mu_j$  = pusat *hidden layer* ke- $j$ ,  $j=1,2,\dots,m$
- $\sigma_j$  = standar deviasi *hidden layer* ke- $j$ ,  $j=1,2,\dots,m$

### 2.6.2. K-Means Cluster

Pada model RBFNN, data input dikelompokkan menjadi beberapa kelompok (cluster). Metode pengelompokkan dibedakan menjadi dua yaitu pengelompokkan secara hierarki dan nonhierarki (Johnson &

Wincern, 2007: 694). Untuk menghindari adanya satu kelompok yang memiliki anggota hanya 1, maka digunakan metode pengelompokan nonhierarki. Salah satu metode yang termasuk metode pengelompokan nonhierarki adalah K-means cluster. Algoritma k'mean kluster adalah sebagai berikut (Johnson & Wincern, 2007: 696):

- Tentukan k cluster dengan k nilai pusat (rata-rata)
- Tempatkan setiap obyek pada kelompok yang mempunyai jarak terdekat dengan pusat, hitung kembali nilai pusat baru.
- Ulangi langkah 2 sampai nilai pusat lama sama dengan nilai pusat baru.

### 2.6.3. Tahapan Pembentukan Model RBFNN

Dalam merancang dan membentuk sebuah model RBFNN terdapat beberapa tahapan penting dalam prosesnya. Beberapa tahapan tersebut adalah sebagai berikut:

- Menentukan *Input* untuk Model RBFNN

Tahap ini bertujuan untuk menentukan banyaknya *input* yang akan digunakan pada model khususnya untuk data deret waktu satu *series*. Dengan menggunakan bantuan plot PACF, maka akan diperoleh *lag-lag* yang mempengaruhi data deret waktu tersebut. Banyak *input* yang akan digunakan, tergantung dari *lag* PACF yang signifikan.

- Menentukan Nilai Pusat dan Varians

Untuk menentukan nilai awal dari nilai pusat dan varians, digunakan *K-means Cluster*. Metode ini akan mengelompokkan data *input* menjadi beberapa kelompok. Selanjutnya nilai pusat dan varians akan dihitung berdasarkan kelompok-kelompok yang terbentuk.

- Menentukan Data *Training* dan *Testing*

Tahap ini tidak kalah penting dengan tahap lainnya. Dengan membagi data menjadi 2 yaitu data *training* dan *testing*. Data *training* digunakan untuk membentuk sebuah model dan data *testing* digunakan untuk menguji model yang terbentuk.

- Menguji Kebaikan Model

Dengan menggunakan nilai MdAPE, sMAPE dan sMdAPE yang dihasilkan dari model, maka dapat dilihat keakuratan model yang terbentuk.

- Menggunakan Model Terbaik untuk Data *Testing*

Setelah diperoleh model terbaik, selanjutnya model tersebut digunakan untuk data *testing*. Pada tahap ini sangat diharapkan model dapat memberikan nilai prediksi yang akurat untuk *output*.

## 2.7. Hybrid Model

Memprediksi deret waktu adalah aspek yang sangat penting dalam hal *Forecasting* yang dilakukan pada observasi masa lampau yang dikumpulkan dan dianalisis guna pengembangan model yang mendasarai sebuah hubungan (Zhang, 2003). Berbagai model analisis deret waktu telah dikembangkan, dari *univariat model* sampai *multivariat model*. Oleh karena itu model-model pada analisis deret waktu sangat populer dan sering digunakan untuk keperluan *forecasting*.

Sementara itu *Neural Network* (NN) adalah salah satu metode yang juga dapat digunakan dalam hal *forecasting*. Menurut Zhang (2003), NN adalah pemodelan yang sangat fleksibel. Dengan NN, tidak ada model khusus dalam pembentukannya. Model yang dihasilkan mengadaptasi pola yang dihasilkan dari data.

Kedua model tersebut sangat banyak digunakan untuk hal *forecasting*, tapi tidak diantara kedua model tersebut cocok untuk keadaan-keadaan berbagai fenomena. Oleh karena itu Zhang (2003) mengusulkan sebuah model *Hybrid* untuk *forecasting* dengan mempertimbangkan struktur *linier autocorrelation* dan komponen *nonlinier* dengan persamaan sebagai berikut:

$$y_t = L_t + N_t \quad (2.30)$$

dimana  $L_t$  adalah komponen *linier* dan  $N_t$  adalah komponen *nonlinier*.

Kedua komponen tersebut diestimasi dari data menggunakan masing-masing

metode. Untuk model pertama yang mewakili komponen *linier*, model tersebut akan menghasilkan *residual* dari model *linier* yang mengandung hubungan *nonlinier*.

$$e_t = y_t - \hat{L}_t \quad (2.31)$$

dimana  $\hat{L}_t$  adalah nilai prediksi untuk waktu ke- $t$ . *Residual* merupakan hal penting dalam mendiagnosa kecukupan model *linier*. Model *linier* dikatakan belum memenuhi kecukupan jika masih terdapat struktur korelasi *linier* pada *residuals* (Zhang, 2003). Dengan memodelkan *resudal* menggunakan NN, maka hubungan *nonlinier* dapat ditemukan. Dengan  $n$  input, maka model NN yang terbentuk adalah sebagai berikut (Zhang, 2003):

$$e_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t \quad (2.32)$$

dimana  $f$  adalah fungsi *nonlinier* yang ditentukan oleh NN dan  $\varepsilon_t$  adalah galat acak. Dengan menganggap bahwa persamaan (2.32) sebagai  $\hat{N}_t$  maka persamaan (2.27) akan menjadi sebagai berikut:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (2.33)$$

## 2.8. Ukuran Ketepatan Prediksi

Salah satu ukuran ketepatan prediksi yang sering digunakan adalah *Mean Absolute Percentage Error (MAPE)*. Namun menurut Gooijer (2006) nilai MAPE akan bermasalah jika data deret waktu mempunyai nilai mendekati nol atau sama dengan nol. Oleh karena itu ada beberapa ukuran ketepatan yang dapat digunakan untuk memperbaiki masalah tersebut seperti *Median Absolute Percentage Error (MdAPE)*, *Symmetric Mean Absolute Percentage Error (sMAPE)*, dan *Symmetric Median Absolute Percentage Error (sMdAPE)*.

### 2.8.1. Median Absolute Percentage Error (MdAPE)

Menurut Amstrong (1992) MdAPE mempunyai persamaan sebagai berikut:

$$APE_t = \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| \times 100\% \quad (2.34)$$

$$MdAPE = APE_{((n+1)/2)} \quad (2.35)$$

untuk n ganjil dan

$$MdAPE = \frac{1}{2} (APE_{(n/2)} + APE_{((n/2)+1)}) \quad (2.36)$$

untuk n genap, dimana :

$APE_t$  = *Absolute Percentage Error* pada waktu ke t

$F_t$  = Nilai prediksi pada waktu ke t

$X_t$  = Nilai Aktual pada waktu ke t

### 2.8.2. *Symmetric Mean Absolute Percentage Error (sMAPE)*

Menurut Makridakis (2000), sMAPE dapat dituliskan seperti berikut:

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{(|Y_t| + |\hat{Y}_t|) / 2} \times 100\% \quad (2.37)$$

dengan :

$F_t$  = Nilai prediksi pada waktu ke t

$X_t$  = Nilai Aktual pada waktu ke t

$n$  = Banyak observasi

### 2.8.3. *Symmetric Median Absolute Percentage Error (sMdAPE)*

Menurut Hyndman (2005), MdAPE memiliki kelemahan karena menitikberatkan pada nilai *error* yang positif. Oleh karena itu digunakan sMdAPE dengan persamaan sebagai berikut:

$$sAPE = \frac{|X_t - F_t|}{(X_t + F_t) / 2} \times 100\% \quad (2.38)$$

$$sMdAPE = sAPE_{((n+1)/2)} \quad (2.39)$$

untuk n ganjil dan

$$sMdAPE = \frac{1}{2} (sAPE_{(n/2)} + sAPE_{((n/2)+1)}) \quad (2.40)$$

untuk n genap, dimana :

$sAPE_t$  = *Symmetric Absolute Percentage Error* pada waktu ke t

$F_t$  = Nilai prediksi pada waktu ke t

$X_t$  = Nilai Aktual pada waktu ke t

$n$  = Banyak observasi

## 2.9. Penelitian Sebelumnya

Pada penelitian-penelitian sebelumnya pendekatan *Hierarchical Time Series* pernah dilakukan dengan berbagai macam data dengan struktur hirarki. Penelitian-penelitian tersebut dirangkum pada Tabel 2.3.

Tabel 2.3. Penelitian Sebelumnya

No	Penulis	Data	Metode	Level	Metode Terbaik
1	Athanasopoulos, et al. (2007)	<i>Australian Tourism</i>	- <i>Bottom-up</i> - <i>Top-down HP</i> - <i>Top-down FP</i> - <i>Combination</i>	2	<i>Top-down FP</i>
2	Utari dan Suhartono (2011)	Permintaan BBM	- <i>Bottom-up</i> - <i>Top-down HP</i> - <i>Top-down FP</i>	1	<i>Top-down</i>
3	Shang, et al. (2013)	<i>Regional Infant Mortality</i>	- <i>Individual</i> - <i>Bottom-up</i> - <i>Combination</i>	3	<i>Combination</i>
4	Prayoga, et al. (2015)	<i>Motorcycle Sales</i>	- <i>Bottom-up</i> - <i>Top-down HP</i> - <i>Top-down FP</i> - <i>Combination</i>	1	<i>Bottom-up</i>
5	Morgan and Kourentzes (2015)	Simulation	- <i>Bottom-up</i> - <i>Top-down HP</i> - <i>Top-down FP</i> - <i>Combination</i>	K	<i>Combination</i>



Halaman ini sengaja dikosongkan

## BAB 3

### METODOLOGI

#### 3.1. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Berita Resmi Statistik (BRS) Badan Pusat Statistik Provinsi Jawa Tengah seperti terlampir pada *Lampiran 1*. Variabel penelitian yang digunakan dapat dilihat pada Tabel 3.1. dengan periode dari Januari 2007 sampai Desember 2014 sebagai data *training* dan periode Januari 2015 sampai Desember 2015 sebagai data *testing*. Satuan data yang digunakan Juta US\$.

#### 3.2. Metode Analisis

Dalam melakukan analisis pada penelitian ini, terdapat beberapa tahapan-tahapan yang harus diselesaikan yaitu sebagai berikut:


- a. Pemodelan ARIMA untuk setiap variabel di level 0 dan level 1 dengan langkah-langkah sebagai berikut:
  - Melakukan transformasi atau *differencing* jika data deret waktu tidak stasioner.
  - Mengidentifikasi model ARIMA dengan menghitung dan dan mendapatkan pola ACF dan PACF.
  - Mengestimasi Parameter
  - Menguji deret  $a_t$  apakah memnuhi asumsi *white noise*
  - Mendapatkan hasil prediksi dengan model ARIMA yang sesuai.
- b. Pemodelan RBFNN untuk setiap variabel di level 0 dan level 1 dengan langkah-langkah sebagai berikut:
  - Menghitung dan mendapatkan pola ACF PACF.
  - Menentukan *input* untuk model RBFNN berdasarkan pola ACF dan PACF.
  - Menentukan nilai pusat dan varians berdasarkan *K-means Cluster*.
  - Mendapatkan kriteria terbaik dari beberapa nilai pusat dan varians.
  - Mendapatkan hasil prediksi dengan model RBFNN terbaik.
- c. Pemodelan *Hybrid* ARIMA-RBFNN untuk setiap variabel di level 0 dan level 1 dengan langkah-langkah sebagai berikut:


- Memodelkan ARIMA untuk setiap variabel di level 0 dan level 1 dan mendapatkan hasil prediksi ARIMA ( $\hat{L}_t$ ).
  - Mendapatkan *Residuals* ARIMA dari masing-masing variabel di level 0 dan level 1.
  - Memodelkan RBFNN untuk setiap *Residuals* ARIMA ( $\hat{N}_t$ ) di level 0 dan level 1.
  - Menghitung nilai prediksi dengan rumus  $\hat{y}_t = \hat{L}_t + \hat{N}_t$
  - Mendapatkan hasil prediksi dengan model *Hybrid* ARIMA-RBFNN terbaik.
- d. Melakukan prediksi hirarki dengan pendekatan *Bottom-up*, *Top-down* Proporsi Historis, dan *Top-down* Proporsi Prediksi dengan model prediksi ARIMA.
  - e. Melakukan prediksi hirarki dengan pendekatan *Bottom-up*, *Top-down* Proporsi Historis, dan *Top-down* Proporsi Prediksi dengan model prediksi RBFNN
  - f. Melakukan prediksi hirarki dengan pendekatan *Bottom-up*, *Top-down* Proporsi Historis, dan *Top-down* Proporsi Prediksi dengan model prediksi *Hybrid* ARIMA-RBFNN
  - g. Melakukan pemilihan model terbaik dengan kriteria MdAPE, sMAPE, dan sMdAPE.
  - h. Melakukan peramalan beberapa beberapa periode kedepan dengan model terbaik.

Tabel 3.1. Variabel Penelitian


Level	Notasi	Nama Variabel
0	$y_t$	Nilai Ekspor Keseluruhan
1	$y_{1,t}$	Binatang hidup, produk hewani
	$y_{2,t}$	Produk nabati
	$y_{3,t}$	Minyak dan lemak hewani atau nabati dan produk disosiasinya
	$y_{4,t}$	Bahan makan olahan, minuman, minuman keras dan cuka
	$y_{5,t}$	Produk mineral
	$y_{6,t}$	Produk kimia dan produk industri yang ada
	$y_{7,t}$	Plastik dan barang dari plastik, karet dan barang dari karet
	$y_{8,t}$	Jangat dan kulit mentah, kulit samak, kulit berbulu dan barangnya, barang untuk bepergian, tas tangan dan tempat simpan semacamnya, barang dari usus (selain usus ulat sutera)
	$y_{9,t}$	Kayu dan barang dari kayu, arang kayu, gabus dan barang dari gabus, barang jerami, rumput esparto, atau dari bahan anyaman lainnya, keranjang dan barang anyaman
	$y_{10,t}$	Pulp dari kayu atau dari bahan selulosa berserat lainnya, kertas atau kertas karton (bekas dan sisa) yang diperoleh kembali, kertas dan kertas karton dan barangnya
	$y_{11,t}$	Tekstil dan barang tekstil
	$y_{12,t}$	Alas kaki, tutup kepala, payung, payung panas, tongkat jalan, tongkat duduk, cambuk, pecut dan bagiannya, bulu unggas olahan dan dan barangnya, bunga tiruan, barang dari rambut manusia
	$y_{13,t}$	Barang dari bat u, gips, semen, asbes, mika atau dari bahan
	$y_{14,t}$	Logam tidak mulia dan barang dari logam tidak mulia
	$y_{15,t}$	Mesin dan pesawat mekanik, barang dan perlengkapan listrik, bagiannya, barang-barang elektronik dan barang yang semacam itu
	$y_{16,t}$	Kendaraan, pesawat terbang, kendaraan air dan perlengkapan pengangkutan
	$y_{17,t}$	Alat dan aparat optik, fotografi, sinematografi, ukur, peneliti, presisi, kedokteran dan bedah, lonceng dan arloji, instrumen musik, bagian dan perlengkapannya
	$y_{18,t}$	Bermacam-macam barang hasil pabrik
	$y_{19,t}$	Hasil seni, barang kegemaran kaum pengumpul, barang antik

### 3.3. Diagram Alir Penelitian







Gambar 3.1. Diagram Alir Penelitian



Gambar 3.2. Diagram Alir Penelitian (Lanjutan)



Gambar 3.3. Diagram Alir Penelitian (Lanjutan)



Gambar 3.4. Diagram Alir Penelitian (Lanjutan)



Halaman ini sengaja dikosongkan

## BAB 4


### HASIL DAN PEMBAHASAN

#### 4.1. Deskripsi Data


Data yang digunakan dalam penelitian ini adalah data sekunder nilai Ekspor Provinsi Jawa Tengah periode Januari 2007 sampai Desember 2015 yang terlampir pada Lampiran 1. Pola data nilai ekspor provinsi Jawa Tengah dapat dilihat pada Gambar 4.1. Untuk menentukan model terbaik, data dibagi menjadi 2 bagian yaitu data dari tahun 2007 sampai 2014 sebagai data *training* dan data tahun 2015 sebagai data *testing*. Hasil statistika deksriptif data nilai ekspor Jawa Tengah pada level 0 dan level 1 dapat dilihat pada Tabel 4.1.

Tabel 4.1. Statistika deskriptif data nilai ekspor Jawa Tengah

Level	Komoditas	Mean	Min	Max
0	$y_t$	364,68	119,51	587,39
1	$y_{1,t}$	7,63	3,65	13,84
	$y_{2,t}$	5,26	2,00	9,01
	$y_{3,t}$	10,64	0,00	36,54
	$y_{5,t}$	10,14	2,71	25,14
	$y_{5,t}$	23,97	0,00	104,84
	$y_{6,t}$	11,68	1,77	59,90
	$y_{7,t}$	7,88	1,42	14,45
	$y_{8,t}$	1,73	0,43	4,66
	$y_{9,t}$	57,87	16,33	96,94
	$y_{10,t}$	3,14	1,60	5,44
	$y_{11,t}$	141,76	48,63	221,19
	$y_{12,t}$	2,03	0,52	4,16
	$y_{13,t}$	5,23	2,56	14,58
	$y_{14,t}$	2,05	0,78	4,65
	$y_{15,t}$	15,90	2,64	29,02
	$y_{16,t}$	0,16	0,00	1,47
	$y_{17,t}$	2,35	0,60	10,22
	$y_{18,t}$	55,19	29,83	185,58
	$y_{19,t}$	0,08	0,00	0,33



Gambar 4.1. *Time Series Plot* Level 0 (Nilai Ekspor Total)



Gambar 4.2. *Time Series Plot* Level 1 (Nilai Ekspor Komoditas)

. Berdasarkan Tabel 4.1 dapat diketahui bahwa nilai ekspor komoditas  $y_{11,t}$  (Tekstil dan Barang Tekstil) merupakan nilai ekspor yang mendominasi di wilayah Jawa Tengah dengan rata-rata nilai ekspor 141,76 Juta US\$, nilai terbesar 221,19 Juta US\$ dan nilai terendah 48,63 juta US\$.


#### 4.2. Pemodelan ARIMA

Model ARIMA merupakan salah satu pemodelan deret waktu yang dapat mengatasi fenomena tren maupun musiman. Model ARIMA mensyaratkan

data deret waktu memenuhi asumsi stasioner dalam *mean* dan *varians*. Terdapat beberapa tahapan dalam pemodelan ARIMA yaitu tahap identifikasi, estimasi, dan uji diagnostik. Pada pemodelan ARIMA, data deret waktu dibagi menjadi dua bagian yaitu data *training* dengan periode Januari 2007 sampai Desember 2014 dan data *testing* dari periode Januari 2015 sampai Desember 2014. Pemodelan ARIMA data nilai ekspor Jawa Tengah dilakukan pada level 0 dan level 1 dengan bantuan *software* MINITAB, R dan SAS.

#### 4.2.1. Pemodelan ARIMA Nilai Ekspor Total (Level 0)

Nilai ekspor total mempunyai pola yang cenderung naik atau tren dengan nilai tertinggi terjadi pada bulan Desember 2013 dengan nilai 587,39 Juta US\$ dan nilai terendah terjadi pada bulan Januari 2009 dengan nilai 119,51 Juta US\$. *Time series plot* ekspor total ditampilkan pada Gambar 4.3.




Gambar 4.3. *Time Series Plot* Ekspor Total

##### - Identifikasi

Pada tahap identifikasi, akan diselidiki apakah data deret waktu telah memenuhi syarat stasioner dalam *mean* dan *varians*. Tahap pertama adalah menyelidiki kestasioneritas dalam *varians* menggunakan Box-Cox Plot. Nilai  $\lambda$  yang diperoleh pada Box-Cox Plot mempengaruhi transformasi yang digunakan. Jika nilai  $\lambda = 1$  maka tidak perlu dilakukan transformasi yang berarti bahwa data telah


stasioner dalam varians. Box-Cox Plot sebelum transformasi ditampilkan pada Gambar 4.4.




Gambar 4.4. Box-Cox Plot Ekspor Total

Berdasarkan Gambar 4.4. diperoleh  $\lambda = 1$ . Hal ini mengindikasikan bahwa tidak perlu dilakukan transformasi karena data telah stasioner dalam varians.

Setelah data deret waktu memenuhi asumsi stasioner dalam varians, selanjutnya adalah menyelidiki apakah data deret waktu memenuhi asumsi stasioner *mean*. Dengan bantuan *software R* diperoleh nilai  $P\text{-Value} = 0,04$  dengan hipotesis ( $H_0$ ) adalah deret waktu tidak stasioner dalam *mean* dan hipotesis ( $H_1$ ) adalah deret waktu telah stasioner dalam *mean* serta  $\alpha = 5\%$  maka diperoleh kesimpulan bahwa data telah memenuhi asumsi stasioner dalam *mean*.



Gambar 4.5. ACF Ekspor Total



Gambar 4.6. PACF Ekspor Total

Setelah asumsi stasioner *mean* dan varians terpenuhi selanjutnya adalah mengecek ACF dan PACF dari data deret waktu. Plot ACF dan PACF ekspor total ditampilkan pada Gambar 4.5. dan Gambar 4.6. Berdasarkan plot ACF dan PACF, model awal yang mungkin terbentuk adalah ARIMA(2,0,0) dan ARIMA(3,0,0).

- Estimasi

Estimasi dan uji signifikansi parameter dilakukan dengan melihat nilai *P-Value* pada output SAS yang ditampilkan pada Tabel 4.2.

Tabel 4.2. Estimasi Parameter Ekspor Total.

Model ARIMA	Parameter	Estimasi	SE	t-Value	P-Value	Keputusan
ARIMA (2,0,0)	$\phi_1$	0,58075	0,09434	6,16	< 0,0001	Signifikan
	$\phi_2$	0,41925	0,09497	4,41	< 0,0001	Signifikan
ARIMA (3,0,0)	$\phi_1$	0,52974	0,10316	5,13	<,0001	Signifikan
	$\phi_2$	0,35148	0,11257	3,12	0,0024	Signifikan
	$\phi_3$	0,11878	0,10483	1,13	0,2601	Tidak Signifikan

Berdasarkan tabel 4.2. model yang sesuai adalah ARIMA (2,0,0) karena semua paramater signifikan pada taraf  $\alpha = 5\%$  . Maka model ARIMA untuk ekspor total adalah:

$$Y_t = 0,58075Y_{t-1} + 0,41925Y_{t-2} + a_t$$

Tahap selanjutnya adalah melakukan pengecekan apakah model ARIMA (2,0,0) telah memenuhi asumsi *White Noise*.

- Uji Diagnostik

Pengujian diagnostik bertujuan untuk menguji apakah residual dari model ARIMA telah mengikuti proses *white noise*. Hasil pengujian diagnostik model ARIMA ditunjukkan pada Tabel 4.3.

Tabel 4.3. Pengujian Diagnostik Ekspor Total


Series	Lag	Q	DF	P-Value
Total	6	3,44	4	0,4871
	12	8,21	10	0,6086
	18	10,9	16	0,8155
	24	12,37	22	0,9493

Berdasarkan tabel 4.3. Nilai *P-Value* >  $\alpha$  (5%) dengan hipotesis ( $H_0$ ) adalah kecukupan model terpenuhi (*white noise*) dan hipotesis ( $H_1$ ) adalah kecukupan model belum terpenuhi ( tidak *white noise*)

maka dapat disimpulkan bahwa model ARIMA(2,0,0) telah memenuhi syarat kecukupan model *white noise* dan layak digunakan pada tahap selanjutnya.

#### 4.2.2. Pemodelan ARIMA Nilai Ekspor Komoditas (Level 1)

Pada tahap pemodelan ARIMA untuk nilai ekspor komoditas (level 1) terdapat 19 series yang akan dimodelkan. Pemodelan pertama yang akan dilakukan adalah pemodelan ARIMA nilai ekspor komoditas 1 (komoditas binatang hidup dan produk hewani). Nilai ekspor komoditas binatang hidup dan produk hewani mempunyai pola yang cenderung konstan, dengan nilai tertinggi terjadi pada bulan Nopember 2011 dengan nilai 13,84 Juta US\$ dan nilai terendah terjadi pada bulan Agustus 2013 dengan nilai 3,65 Juta US\$. *Time series plot* Komoditas 1 ditampilkan pada Gambar 4.7.




Gambar 4.7. *Time Series Plot* Komoditas 1




- Identifikasi

Pada tahap identifikasi, akan diselidiki apakah data deret waktu telah memenuhi syarat stasioner dalam *mean* dan *varians*. Tahap pertama adalah menyelidiki kestasioneritas dalam *varians* menggunakan Box-Cox Plot. Nilai  $\lambda$  yang diperoleh pada Box-Cox Plot mempengaruhi transformasi yang digunakan. Jika nilai  $\lambda = 1$  maka tidak perlu dilakukan transformasi yang berarti bahwa data telah stasioner dalam *varians*.



Gambar 4.8. Box-Cox *Plot* Sebelum Transformasi Komoditas 1




Gambar 4.9. Box-Cox Plot Setelah Transformasi Komoditas 1


Berdasarkan Gambar 4.8. diperoleh  $\lambda = 0,5$ . Hal ini mengindikasikan bahwa perlu dilakukan transformasi. Box-Cox Plot setelah

transformasi ditampilkan pada Gambar 4.9. dengan nilai  $\lambda = 1$ . Hal ini mengindikasikan bahwa data telah stasioner dalam varians.

Setelah data deret waktu memenuhi asumsi stasioner dalam varians, selanjutnya adalah menyelidiki apakah data deret waktu memenuhi asumsi stasioner *mean*. Dengan bantuan *software* R diperoleh nilai *P-Value* = 0,01 dengan *differencing* lag 1 serta hipotesis ( $H_0$ ) adalah deret waktu tidak stasioner dalam *mean* dan hipotesis ( $H_1$ ) adalah deret waktu telah stasioner dalam *mean* dan  $\alpha = 5\%$  maka diperoleh kesimpulan bahwa data telah stasioner dalam *mean*.



Gambar 4.10. ACF Komoditas 1 (*differencing* lag 1)



Gambar 4.11. PACF Komoditas 1 (*differencing* lag 1)

Setelah asumsi stasioner *mean* dan varians terpenuhi selanjutnya adalah mengecek ACF dan PACF dari data deret waktu. Plot ACF dan PACF komoditas 1 ditampilkan pada Gambar 4.10. dan Gambar 4.11. Pada plot ACF dan PACF mengindikasikan bahwa model yang terbentuk adalah MA(1) dengan diff(1). Maka model dugaan awal adalah ARIMA(0,1,1).

- Estimasi

Estimasi dan uji signifikansi parameter dilakukan dengan melihat nilai *P-Value* pada output SAS yang ditampilkan pada Tabel 4.4.

Tabel 4.4. Estimasi Parameter Komoditas 1

Model ARIMA	Parameter	Estimasi	SE	t-Value	P-Value	Keputusan
ARIMA (0,1,1)	$\theta_1$	0,52467	0,08788	5,97	< 0,0001	Signifikan

Berdasarkan tabel 4.4. model yang sesuai adalah ARIMA (0,1,1) karena paramater telah signifikan pada taraf  $\alpha = 5\%$  . Maka model ARIMA untuk komoditas 1 adalah:

$$\dot{Y}_{1,t} = \dot{Y}_{1,t-1} + a_{1,t} - 0,5246a_{1,t-1}$$

$$\text{dengan } \dot{Y}_{1,t} = \sqrt{Y_{1,t}}$$

- Uji Diagnostik

Pengujian diagnostik bertujuan untuk menguji apakah residual dari model ARIMA telah mengikuti proses *white noise*. Hasil pengujian diagnostik model ARIMA ditunjukkan pada Tabel 4.5.

Tabel 4.5. Pengujian Diagnostik Komoditas 1

Series	Lag	Q	DF	P-Value
1	6	1,28	5	0,9374
	12	9,96	11	0,5340
	18	14,8	17	0,6097
	24	28,42	23	0,2003

Berdasarkan tabel 4.5. Nilai *P-Value* >  $\alpha$  (5%) dengan hipotesis ( $H_0$ ) adalah kecukupan model terpenuhi (*white noise*) dan hipotesis ( $H_1$ ) adalah kecukupan model belum terpenuhi ( tidak *white noise*)

maka dapat disimpulkan bahwa model ARIMA(0,1,1) telah memenuhi syarat kecukupan model *white noise* dan layak digunakan pada tahap selanjutnya.

Dengan tahapan yang sama, dilakukan pemodelan ARIMA untuk semua nilai ekspor komoditas (level 1) dengan hasil keseluruhan pemodelan ARIMA ditampilkan pada tabel 4.6.

Tabel 4.6. Hasil Keseluruhan Pemodelan ARIMA

Komoditas	Order ARIMA	Model ARIMA
Ekspor Total	ARIMA (2,0,0)	$Y_t = 0,58075Y_{t-1} + 0,41925Y_{t-2} + a_t$
Komoditas 1	ARIMA (0,1,1)	$\dot{Y}_{1,t} = \dot{Y}_{1,t-1} + a_{1,t} - 0,5246a_{1,t-1}$
Komoditas 2	ARIMA (1,1,1)	$\dot{Y}_{2,t} = 1,84060\dot{Y}_{2,t-1} + 0,84060\dot{Y}_{2,t-2} + a_{2,t} - 0,44551a_{2,t-1}$
Komoditas 3	ARIMA (0,1,1)	$\dot{Y}_{3,t} = \dot{Y}_{3,t-1} + a_{3,t} - 0,72927a_{3,t-1}$
Komoditas 4	ARIMA (0,1,1)	$\dot{Y}_{4,t} = \dot{Y}_{4,t-1} + a_{4,t} - 0,57721a_{4,t-1}$
Komoditas 5	ARIMA (0,1,1)	$\dot{Y}_{5,t} = \dot{Y}_{5,t-1} + a_{5,t} - 0,68363a_{5,t-1}$
Komoditas 6	ARIMA (0,1,1)	$\dot{Y}_{6,t} = \dot{Y}_{6,t-1} + a_{6,t} - 0,73597a_{6,t-1} + 0,22364I_T^{25}$
Komoditas 7	ARIMA (1[10],1,0)	$\dot{Y}_{7,t} = 0,74077\dot{Y}_{7,t-1} + 0,25923\dot{Y}_{7,t-2} + 0,27835\dot{Y}_{7,t-10} - 0,27835\dot{Y}_{7,t-11} + a_{7,t}$
Komoditas 8	ARIMA (2,0,0)	$\dot{Y}_{8,t} = 0,70916\dot{Y}_{8,t-1} + 0,28986\dot{Y}_{8,t-2} + a_{8,t}$

---

Komoditas 9	ARIMA (0,1,1)	$\dot{Y}_{9,t} = \dot{Y}_{9,t-1} + a_{9,t} - 0,72514a_{9,t-1} + 2,56967I_T^{(11)} + 2,26135I_T^{(36)} - 1,73411I_T^{(25)} - 1,78513I_T^{(80)}$
Komoditas 10	ARIMA(1,1,1)	$\dot{Y}_{10,t} = 1,33973\dot{Y}_{10,t-1} + 0,33973\dot{Y}_{10,t-2} + a_{10,t} - 0,97462a_{10,t-1}$
Komoditas 11	ARIMA(2,1,0)	$\dot{Y}_{11,t} = \dot{Y}_{11,t-1} + a_{11,t} - 0,64243a_{11,t-1} - 2,68917I_T^{(25)}$
Komoditas 12	ARIMA(1,0,1)(0,1,1) <sup>6</sup>	$Y_{12,t} = Y_{12,t-6} + 0,84083Y_{12,t-1} - 0,84083Y_{12,t-7} + a_{12,t} - 0,60594a_{12,t-1} - 0,74805a_{12,t-6} + 0,45327a_{12,t-7}$
Komoditas 13	ARIMA(0,1,1)	$\dot{Y}_{13,t} = \dot{Y}_{13,t-1} + a_{13,t} - 0,7185a_{13,t-1} - 0,03028I_T^{(1)} - 0,18224I_T^{(31)}$
Komoditas 14	ARIMA(0,1,1)	$\dot{Y}_{14,t} = \dot{Y}_{14,t-1} + a_{14,t} - 0,74116a_{14,t-1} + 0,38639I_T^{(5)} - 0,25661I_T^{(55)}$
Komoditas 15	ARIMA(0,1,1)	$Y_{15,t} = Y_{14,t-1} + a_{14,t} - 0,52686a_{14,t-1} - 7,49851I_T^{(23)}$
Komoditas 16	ARIMA(0,1,1)	$\dot{Y}_{14,t} = \dot{Y}_{14,t-1} + a_{14,t} - 0,77036a_{14,t-1}$
Komoditas 17	ARIMA([1[20],0,0)	$\dot{Y}_{17,t} = 0,89755\dot{Y}_{17,t-1} + 0,10245\dot{Y}_{17,t-20} + a_{17,t} + 1,19167I_T^{(92)}$
Komoditas 18	ARIMA(0,1,1[23])	$\dot{Y}_{18,t} = \dot{Y}_{18,t-1} + a_{18,t} - 0,5766a_{18,t-1} - 0,37501a_{18,t-23} + 0,28001I_T^{(37)} - 0,11433I_T^{(22)} - 0,13808I_T^{(25)} + 0,13761I_T^{(31)} - 0,13945I_T^{(80)} - 0,11834I_T^{(45)} - 0,09118I_T^{(57)}$

---

---

Komoditas 19	ARIMA(0,1,1)	$\dot{Y}_{19,t} = \dot{Y}_{19,t-1} + a_{19,t} - 0,61712a_{19,t-1}$
--------------	--------------	--

---

### 4.3. Pemodelan RBFNN

Model RBFNN merupakan salah satu model *Neural Network* yang dapat digunakan untuk memprediksi data deret waktu. Dalam pemodelan RBFNN terdapat beberapa tahapan yaitu menentukan input, menentukan nilai pusat dan varians dan menentukan model terbaik. Dalam menentukan *input* pada model RBFNN, digunakan plot ACF dan PACF dari data yang digunakan. Sedangkan untuk menentukan nilai pusat dan varians, digunakan *K-means Cluster*. Pemodelan RBFNN data nilai ekspor Jawa Tengah dilakukan pada level 0 dan level 1 dengan bantuan *software* MATLAB.

#### 4.3.1. Pemodelan RBFNN Nilai Ekspor Total (level 0)

Nilai ekspor total yang digunakan dalam menentukan model terbaik adalah nilai ekspor dari periode Januari 2007 sampai Desember 2014 sebanyak 96 observasi.

- Menentukan Input

Dalam menentukan input model RBFNN digunakan pertimbangan berdasarkan plot ACF dan PACF yang ditampilkan pada Gambar 4.5. dan Gambar 4.6. serta model ARIMA yang telah terbentuk. Penentuan input sangat berpengaruh pada model terbaik yang terbentuk. Berdasarkan Gambar 4.5. dan Gambar 4.6. serta model ARIMA (2,0,0) maka dapat diputuskan bahwa input yang digunakan adalah  $Y_{t-1}$  dan  $Y_{t-2}$ .

- Menentukan Nilai Pusat dan Varians

Pada penentuan nilai pusat dan varians, digunakan metode *K-mean Cluster* dengan metode *trial and error*. Banyaknya kluster yang digunakan dalam *trial error* adalah 2, 3, 4, 5 dan 6. Banyaknya kluster yang optimum akan menentukan berapa *hidden layer* yang digunakan.

- Menentukan Model Terbaik

Dalam menentukan model terbaik digunakan kriteria kebaikan MdAPE, sMAPE dan sMdAPE yang ditampilkan pada Tabel 4.7



Tabel 4.7. Pemilihan Model Terbaik Ekspor Total

Kluster	MdAPE	sMAPE	sMdAPE
2	8,444544	11,13992	8,816814
3	8,353411	11,06934	8,216985
4	8,0535	11,14156	8,152796
<b>5</b>	<b>7,883855</b>	<b>11,04884</b>	<b>7,966563</b>
6	8,004106	11,00146	8,16499


Berdasarkan Tabel 4.7 diputuskan kriteria terbaik adalah model RBFNN dengan 2 *neuron input* dan 5 *neuron hidden layer*.

#### 4.3.2. Pemodelan RBFNN Nilai Ekspor Komoditas (level 1)


Pada tahap pemodelan RBFNN untuk nilai ekspor komoditas (level 1) terdapat 19 series yang akan dimodelkan. Pemodelan pertama yang akan dilakukan adalah pemodelan RBFNN nilai ekspor komoditas 1 (komoditas binatang hidup dan produk hewani). Nilai ekspor komoditas 1 yang digunakan dalam menentukan model terbaik adalah nilai ekspor dari periode Januari 2007 sampai Desember 2014 sebanyak 96 observasi.

##### - Menentukan Input

Dalam menentukan input model RBFNN digunakan plot ACF dan PACF data asli yang ditampilkan pada Gambar 4.12 dan Gambar 4.13. Penentuan input sangat berpengaruh pada model terbaik yang terbentuk.



Gambar 4.12. ACF Komoditas 1



Gambar 4.13. PACF Komoditas 1

Berdasarkan Gambar 4.12. dan Gambar 4.13 serta model ARIMA (0,1,1) maka dapat diputuskan bahwa kemungkinan input yang akan digunakan adalah  $Y_{1,t-1}$ ,  $Y_{1,t-2}$  dan  $Y_{1,t-3}$ .

- Menentukan Nilai Pusat dan Varians

Pada penentuan nilai pusat dan varians, digunakan metode *K-mean Cluster* dengan metode *trial and error*. Banyaknya kluster yang digunakan dalam *trial error* adalah 2, 3, 4, 5 dan 6. Banyaknya kluster yang optimum akan menentukan berapa *hidden layer* yang digunakan.

- Menentukan Model Terbaik

Dalam menentukan model terbaik digunakan kriteria kebaikan MdAPE, sMAPE dan sMdAPE yang ditampilkan pada Tabel 4.8.

Tabel 4.8 (b). Pemilihan Model Terbaik Komoditas 1

	Kluster	MdAPE	sMAPE	sMdAPE
2 Input	2	14,90717	18,96857	14,40565
	3	15,54630	17,95433	15,28958
	4	16,36618	18,09037	16,37745
	5	15,65543	17,99865	15,71063
	<b>6</b>	<b>13,82453</b>	<b>17,57994</b>	<b>14,51448</b>

Tabel 4.8 (b). Pemilihan Model Terbaik Komoditas 1

	Kluster	MdAPE	sMAPE	sMdAPE
3 Input	2	16,32562	18,74138	15,96274
	3	14,68496	18,43757	14,78913
	4	14,94145	18,2657	14,62378
	5	14,08629	18,02567	14,87684
	6	15,56369	18,48008	15,33988

Berdasarkan Tabel 4.8 diputuskan bahwa model terbaik adalah model RBFNN dengan 2 *neuron input* dan 6 *neuron hidden layer*.

Dengan tahapan yang sama, dilakukan pemodelan RBFNN untuk semua nilai ekspor komoditas (level 1) dengan hasil keseluruhan pemodelan RBFNN ditampilkan pada tabel 4.9.

Tabel 4.9. Hasil Keseluruhan Pemodelan RBFNN

Series	Input	Hidden Layer	Model
Ekspor Total	2 Neuron	5 Neuron	$Y_t = \sum_{j=1}^2 w_j \phi_j(x)$
Komoditas 1	2 Neuron	6 Neuron	$Y_{1,t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 2	2 Neuron	2 Neuron	$Y_{2,t} = \sum_{j=1}^2 w_j \phi_j(x)$
Komoditas 3	2 Neuron	6 Neuron	$Y_{3,t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 4	2 Neuron	4 Neuron	$Y_{4,t} = \sum_{j=1}^4 w_j \phi_j(x)$
Komoditas 5	2 Neuron	5 Neuron	$Y_{5,t} = \sum_{j=1}^5 w_j \phi_j(x)$
Komoditas 6	2 Neuron	3 Neuron	$Y_{6,t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 7	2 Neuron	6 Neuron	$Y_{7,t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 8	2 Neuron	3 Neuron	$Y_{8,t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 9	3 Neuron	6 Neuron	$Y_{9,t} = \sum_{j=1}^6 w_j \phi_j(x)$

Komoditas 10	2 Neuron	6 Neuron	$Y_{10,t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 11	3 Neuron	4 Neuron	$Y_{11,t} = \sum_{j=1}^4 w_j \phi_j(x)$
Komoditas 12	2 Neuron	3 Neuron	$Y_{12,t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 13	2 Neuron	4 Neuron	$Y_{13,t} = \sum_{j=1}^4 w_j \phi_j(x)$
Komoditas 14	2 Neuron	4 Neuron	$Y_{14,t} = \sum_{j=1}^4 w_j \phi_j(x)$
Komoditas 15	2 Neuron	6 Neuron	$Y_{15,t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 16	2 Neuron	3 Neuron	$Y_{16,t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 17	2 Neuron	3 Neuron	$Y_{17,t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 18	2 Neuron	2 Neuron	$Y_{18,t} = \sum_{j=1}^2 w_j \phi_j(x)$
Komoditas 19	2 Neuron	3 Neuron	$Y_{19,t} = \sum_{j=1}^3 w_j \phi_j(x)$

#### 4.4. Pemodelan Hybrid ARIMA-RBFNN

Model *Hybrid* ARIMA-RBFNN merupakan model gabungan yang mengandung unsur linier dan nonlinier. Dalam hal ini, unsur linier terdapat pada hasil pemodelan data deret waktu dengan ARIMA dan unsur nonlinier terdapat pada residual ARIMA yang kemudian dimodelkan dengan RBFNN. Dalam pemodelan *Hybrid* ARIMA-RBFNN terdapat beberapa tahapan yaitu memodelkan data deret waktu dengan ARIMA dan mendapatkan residual, memodelkan residual dengan RBFNN, menggabungkan hasil prediksi ARIMA dengan hasil prediksi RBFNN dan menentukan model terbaik. Pemodelan *Hybrid* ARIMA-RBFNN data nilai ekspor Jawa Tengah dilakukan pada level 0 dan level 1 dengan bantuan *software* MATLAB.

#### 4.4.1. Pemodelan Hybrid ARIMA-RBFNN Nilai Ekspor Total (level 0)

Dalam pemodelan nilai ekspor total menggunakan Hybrid ARIMA-RBFNN terdapat beberapa tahapan dalam pemodelan yaitu:

- Residual Pemodelan ARIMA

Residual ARIMA yang digunakan merupakan residual yang memenuhi asumsi *white noise* dan berasal dari model ARIMA(2,0,0) dengan banyak observasi = 96.

- Menentukan Input RBFNN

Residual yang digunakan dalam pemodelan merupakan residual yang memenuhi asumsi *white noise*, oleh karena itu dalam menentukan input model RBFNN digunakan kemungkinan minimum input yaitu  $a_{t-1}$  dan  $a_{t-2}$ .

- Menentukan Nilai Pusat dan Varians RBFNN

Pada penentuan nilai pusat dan varians, digunakan metode *K-mean Cluster* dengan metode *trial and error*. Banyaknya kluster yang digunakan dalam *trial error* adalah 2, 3, 4, 5 dan 6. Banyaknya kluster yang optimum akan menentukan berapa *hidden layer* yang akan digunakan.

- Menentukan Model Terbaik

Setelah diperoleh hasil pemodelan dengan RBFNN, selanjutnya adalah menggabungkan komponen linier dan nonlinier serta menentukan model terbaik berdasarkan kriteria kebaikan MdAPE, sMAPE dan sMdAPE yang ditampilkan pada Tabel 4.10.

Tabel 4.10. Pemilihan Model Terbaik Ekspor Total

Kluster	MdAPE	sMAPE	sMdAPE
2	8,500723	11,46285	8,54842
3	8,564381	11,45428	8,446474
4	8,562763	11,42263	8,247025
5	8,163073	11,33058	8,048902
<b>6</b>	<b>7,546591</b>	<b>11,32185</b>	<b>7,687897</b>

Berdasarkan Tabel 4.10 diputuskan bahwa model terbaik adalah model *Hybrid* ARIMA-RBFNN 2 *neuron input* dan 6 *neuron hidden layer*.

#### 4.4.2. Pemodelan Hybrid ARIMA-RBFNN Nilai Ekspor Komoditas (level 1)

Pada tahap pemodelan *Hybrid* ARIMA-RBFNN untuk nilai ekspor komoditas (level 1) terdapat 19 series yang akan dimodelkan. Pemodelan pertama yang akan dilakukan adalah pemodelan *Hybrid* ARIMA-RBFNN nilai ekspor komoditas binatang hidup, produk hewani (Komoditas 1) dengan beberapa tahapan yaitu:

- Residual Pemodelan ARIMA

Residual ARIMA yang digunakan merupakan residual yang memenuhi asumsi *white noise* dan berasal dari model ARIMA(0,1,1) dengan banyak observasi = 95.

- Menentukan Input RBFNN

Residual yang digunakan dalam pemodelan merupakan residual yang memenuhi asumsi *white noise*, oleh karena itu dalam menentukan input model RBFNN digunakan kemungkinan minimum input yaitu  $a_{t-1}$  dan  $a_{t-2}$ .

- Menentukan Nilai Pusat dan Varians RBFNN

Pada penentuan nilai pusat dan varians, digunakan metode *K-mean Cluster* dengan metode *trial and error*. Banyaknya kluster yang digunakan dalam *trial error* adalah 2, 3, 4, 5 dan 6. Banyaknya kluster yang optimum akan menentukan berapa *hidden layer* yang akan digunakan.

- Menentukan Model Terbaik

Setelah diperoleh hasil pemodelan dengan RBFNN, selanjutnya adalah menggabungkan komponen linier dan nonlinier serta menentukan model terbaik berdasarkan kriteria kebaikan MdAPE, sMAPE dan sMdAPE yang ditampilkan pada Tabel 4.11.

Tabel 4.11. Pemilihan Model Terbaik Komoditas 1

Kluster	MdAPE	sMAPE	sMdAPE
2	7,05499	9,194051	6,998919
3	6,9908	9,303605	6,92471
4	7,038513	9,27473	6,961514
5	7,026529	9,294646	6,847828
<b>6</b>	<b>6,990806</b>	<b>9,303605</b>	<b>6,924705</b>

Berdasarkan Tabel 4.11 diputuskan bahwa model terbaik adalah model *Hybrid* ARIMA-RBFNN dengan 2 *neuron input* dan 6 *neuron hidden layer*.

Dengan tahapan yang sama, dilakukan pemodelan *Hybrid* ARIMA-RBFNN untuk semua nilai ekspor komoditas (level 1) dengan hasil keseluruhan pemodelan *Hybrid* ARIMA-RBFNN ditampilkan pada tabel 4.12.

Tabel 4.12. Hasil Keseluruhan Pemodelan *Hybrid* ARIMA-RBFNN

Series	$L_t$	$N_t$
Ekspor Total	$L_t = 0,58075Y_{t-1} + 0,41925Y_{t-2} + a_t$	$N_t = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 1	$\dot{L}_{1t} = \dot{Y}_{1t-1} + a_{1t} - 0,5246a_{1t-1}$	$N_{1t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 2	$\dot{L}_{2t} = 1,52467\dot{Y}_{2t-1} + 0,52467\dot{Y}_{2t-2} + a_{2t} - 0,44551a_{2t-1}$	$N_{2t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 3	$\dot{L}_{3t} = \dot{Y}_{3t-1} + a_{3t} - 0,72927a_{3t-1}$	$N_{3t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 4	$\dot{L}_{4t} = \dot{Y}_{4t-1} + a_{4t} - 0,57721a_{4t-1}$	$N_{4t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 5	$\dot{L}_{5t} = \dot{Y}_{5t-1} + a_{5t} - 0,68363a_{5t-1}$	$N_{5t} = \sum_{j=1}^2 w_j \phi_j(x)$
Komoditas 6	$\dot{L}_{6t} = \dot{Y}_{6t-1} + a_{6t} - 0,73597a_{6t-1} + 0,22364I_T^{25}$	$N_{6t} = \sum_{j=1}^5 w_j \phi_j(x)$
Komoditas 7	$\dot{L}_{7t} = 0,74077\dot{Y}_{7t-1} + 0,25923\dot{Y}_{7t-2} + 0,27835\dot{Y}_{7t-10} - 0,27835\dot{Y}_{7t-11} + a_{7t}$	$N_{7t} = \sum_{j=1}^4 w_j \phi_j(x)$
Komoditas 8	$\dot{L}_{8t} = 0,70916\dot{Y}_{8t-1} + 0,28986\dot{Y}_{8t-2} + a_{8t}$	$N_{8t} = \sum_{j=1}^2 w_j \phi_j(x)$



---

Komoditas 9	$\dot{L}_{9t} = \dot{Y}_{9t-1} + a_{9t} - 0,72514a_{9t-1} + 2,56967I_T^{(11)} + 2,26135I_T^{(36)} - 1,73411I_T^{(25)} - 1,78513I_T^{(80)}$	$N_{9t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 10	$\dot{L}_{10t} = 1,33973\dot{Y}_{10t-1} + 0,33973\dot{Y}_{10t-2} + a_{10t} - 0,97462a_{10t-1}$	$N_{10t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 11	$\dot{L}_{11t} = \dot{Y}_{11t-1} + a_{11t} - 0,64243a_{11t-1} - 2,68917I_T^{(25)}$	$N_{11t} = \sum_{j=1}^4 w_j \phi_j(x)$
Komoditas 12	$L_{12t} = Y_{12t-6} + 0,84083Y_{12t-1} - 0,84083Y_{12t-7} + a_{12t} - 0,60594a_{12t-1} - 0,74805a_{12t-6} + 0,45327a_{12t-7}$	$N_{12t} = \sum_{j=1}^2 w_j \phi_j(x)$
Komoditas 13	$\dot{L}_{13t} = \dot{Y}_{13t-1} + a_{13t} - 0,7185a_{13t-1} - 0,03028I_T^{(1)} - 0,18224I_T^{(31)}$	$N_{13t} = \sum_{j=1}^5 w_j \phi_j(x)$
Komoditas 14	$\dot{L}_{14t} = \dot{Y}_{14t-1} + a_{14t} - 0,74116a_{14t-1} + 0,38639I_T^{(5)} - 0,25661I_T^{(55)}$	$N_{14t} = \sum_{j=1}^2 w_j \phi_j(x)$
Komoditas 15	$L_{15t} = Y_{14t-1} + a_{14t} - 0,52686a_{14t-1} - 7,49851I_T^{(23)}$	$N_{15t} = \sum_{j=1}^5 w_j \phi_j(x)$
Komoditas 16	$\dot{L}_{14t} = \dot{Y}_{14t-1} + a_{14t} - 0,77036a_{14t-1}$	$N_{16t} = \sum_{j=1}^3 w_j \phi_j(x)$
Komoditas 17	$\dot{L}_{17t} = 0,89755\dot{Y}_{17t-1} + 0,10245\dot{Y}_{17t-20} + a_{17t} + 1,19167I_T^{(92)}$	$N_{17t} = \sum_{j=1}^6 w_j \phi_j(x)$
Komoditas 18	$\dot{L}_{18t} = \dot{Y}_{18t-1} + a_{18t} - 0,5766a_{18t-1} - 0,37501a_{18t-23} + 0,28001I_T^{(37)} - 0,11433I_T^{(22)} - 0,13808I_T^{(25)} + 0,13761I_T^{(31)} - 0,13945I_T^{(80)} - 0,11834I_T^{(45)} - 0,09118I_T^{(57)}$	$N_{18t} = \sum_{j=1}^4 w_j \phi_j(x)$

---

---

Komoditas 19     $\dot{L}_{19t} = \dot{Y}_{19t-1} + a_{19t} - 0,61712a_{19t-1}$

---

$$N_{19t} = \sum_{j=1}^3 w_j \phi_j(x)$$

#### 4.5. Pendekatan Hierarchical Time Series

Setelah tahapan pemodelan dengan ARIMA, RBFNN dan *Hybrid* ARIMA-RBFNN selesai, tahap selanjutnya adalah melakukan prediksi dengan pendekatan *Hierarchical Time Series*. Pada tahap ini, pemodelan dibagi menjadi 2 yaitu pemodelan untuk data pada level 0 dan data pada level 1 dengan ketentuan yang ditampilkan pada Tabel 4.83.

Berdasarkan Tabel 4.13 terdapat 6 pemodelan untuk data pada level 0 dan 12 pemodelan untuk data pada level 1. Dari masing-masing pemodelan tersebut akan dipilih pemodelan yang terbaik untuk memprediksi nilai Ekspor Jawa Tengah. Selain menggunakan pemodelan *Hierarchical Time Series*, akan dilakukan juga pemodelan *Independent* yaitu pemodelan tanpa hirarki dengan menggunakan ARIMA, RBFNN dan *Hybrid* ARIMA-RBFNN. Pada pemodelan *Top-down Historical Proportion* digunakan proporsi historis pada periode Januari 2014 – Desember 2014.

Tabel 4.13. Pemodelan *Hierarchical Time Series*


Level 0	Level 1
ARIMA <i>Independent</i>	ARIMA <i>Independent</i>
ARIMA <i>Bottom-up (BU)</i>	ARIMA <i>Top-down Historical Proportion 1 (HP1)</i>
RBFNN <i>Independent</i>	ARIMA <i>Top-down Historical Proportion 2 (HP2)</i>
RBFNN <i>Bottom-up (BU)</i>	ARIMA <i>Top-down Forecast Proportion (FP)</i>
Hybrid <i>Independent</i>	RBFNN <i>Independent</i>
Hybrid <i>Bottom-up (BU)</i>	RBFNN <i>Top-down Historical Proportion 1 (HP1)</i>
	RBFNN <i>Top-down Historical Proportion 2 (HP2)</i>
	RBFNN <i>Top-down Forecast Proportion (FP)</i>
	Hybrid <i>Independent</i>
	Hybrid <i>Top-down Historical Proportion 1 (HP1)</i>
	Hybrid <i>Top-down Historical Proportion 2 (HP2)</i>
	Hybrid <i>Top-down Forecast Proportion (FP)</i>

#### 4.6. Pemilihan Model Terbaik


Pada pemilihan model terbaik, digunakan 3 kriteria ketepatan prediksi yaitu MdAPE, sMAPE, dan sMdAPE. Untuk mengecek keakuratan prediksi berdasarkan jangka waktu digunakan pendekatan *Rolling Forecast Origin* dengan ilustrasi ditunjukkan pada Gambar 4.84. Berikut adalah tahapan *Rolling Forecast Origin*.

- Menentukan model terbaik yang digunakan berdasarkan data *training*.
- Mengestimasi ulang berdasarkan model terbaik dengan ketentuan
  - Melakukan estimasi berdasarkan model terbaik pada observasi  $n+i$  dengan  $i = 0, 1, 2, \dots, N-n$  dimana  $n$  adalah banyaknya observasi data training dan  $N$  adalah banyaknya data keseluruhan.
  - Hitung keakuratan prediksi untuk masing-masing  $i$ .
- Mendapatkan keakuratan prediksi berdasarkan jangka waktu.

Ilustrasi *Rolling Forecast Origin* ditunjukkan pada Gambar 4.14 dan Gambar 4.15. berikut.




Gambar 4.14. Pembagian data *Rolling Forecast Origin*




Gambar 4.15. Proses *Rolling Forecast Origin* pada  $h=1$

Berdasarkan Gambar 4.14. dan Gambar 4.15. titik biru adalah data yang diestimasi ulang, sedangkan titik merah adalah hasil prediksi untuk masing-masing  $h$  . Dimana  $h$  adalah prediksi kedepan.



Gambar 4.16. Keakuratan Prediksi Pada Level 0 dengan sMAPE



Gambar 4.17. Keakuratan Prediksi Pada Level 1 dengan sMAPE

Hasil perhitungan kriteria kebaikan model menggunakan pendekatan *Bottom-up*, *Top-down* proporsi historis dan *Top-down* proporsi prediksi dengan pemodelan ARIMA, RBFNN dan *Hybrid* ARIMA-RBFNN menggunakan *Origin Rolling Forecast* ditampilkan pada Gambar 4.16. dan Gambar 4.17. serta Tabel 4.14 dengan contoh kriteria yang digunakan adalah sMAPE.

Tabel 4.14. Pemilihan Model dengan Salah Satu Kriteria Kebaikan Model yang digunakan yaitu sMAPE


h	Level 0			Level 1		
	ARIMA BU	RBFNN BU	HYBRID BU	ARIMA Ind	ARIMA FP	HYBRID Ind
1	<b>6,15</b>	7,39	6,28	<b>21,74</b>	22,10	21,81
2	6,58	<b>6,15</b>	6,78	<b>23,83</b>	24,33	24,70
3	7,87	<b>6,29</b>	8,18	<b>23,78</b>	24,02	25,02
4	8,25	<b>6,37</b>	8,59	<b>24,56</b>	25,06	24,98
5	7,87	<b>5,41</b>	8,20	<b>25,00</b>	<b>25,00</b>	25,64
6	8,03	<b>6,24</b>	8,61	<b>25,22</b>	25,44	26,27
7	6,12	<b>5,23</b>	6,80	25,45	25,80	<b>25,38</b>
8	<b>2,71</b>	3,03	3,54	26,02	26,69	<b>25,61</b>
9	2,04	3,06	<b>1,88</b>	<b>25,35</b>	25,65	25,92
10	<b>4,16</b>	4,79	4,39	22,53	<b>22,16</b>	23,02
11	5,67	6,66	<b>5,43</b>	21,22	<b>21,10</b>	21,56
12	1,82	0,91	<b>0,54</b>	<b>20,15</b>	20,32	20,62

Berdasarkan Gambar 4.16. dan Gambar 4.17 serta Tabel. 4.14. diperoleh kesimpulan bahwa pada level 0 yaitu Nilai Ekspor Total, pendekatan prediksi *Bottom-up* dengan pemodelan RBFNN dapat digunakan untuk prediksi jangka pendek dan menengah. Sedangkan pendekatan prediksi *Bottom-up* dengan pemodelan Hybrid ARIMA-RBFNN dapat digunakan untuk prediksi jangka Panjang. Pada level 1 yaitu Nilai Ekspor Komoditas, pendekatan prediksi *independent* (tanpa hirarki) dengan pemodelan ARIMA dapat digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang. Berdasarkan Lampiran 5. jika dilihat berdasarkan masing-masing pemodelan, maka diperoleh kesimpulan bahwa untuk pemodelan ARIMA, pada level 0 (Ekspor Total) pendekatan prediksi *Bottom-up* dapat digunakan untuk prediksi jangka pendek dan menengah. Dan untuk prediksi jangka panjang pendekatan prediksi *independent* (tanpa hirarki) dapat digunakan. Sedangkan pada level 1 (Ekspor Komoditas), pendekatan prediksi *independent* (tanpa hirarki) dapat


digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang. Untuk pemodelan RBFNN, pada level 0 (Ekspor Total) pendekatan prediksi hirarki *Bottom-up* dapat digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang. Sedangkan pada level 1 (Ekspor Komoditas), pendekatan prediksi *Top-down* Proporsi Historis 1 dapat digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang. Untuk pemodelan *Hybrid* ARIMA-RBFNN, pada level 0 (Ekspor Total) pendekatan prediksi *Bottom-up* dapat digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang. Sedangkan pada level 1 (Ekspor Komoditas), pendekatan prediksi *Bottom-up* dapat digunakan untuk prediksi jangka pendek dan menengah. Sedangkan untuk jangka panjang, pendekatan prediksi *Top-down* Proporsi Prediksi dapat digunakan.

#### 4.7. Peramalan Nilai Ekspor Provinsi Jawa Tengah

Berdasarkan tahapan pemilihan model terbaik, maka tahap selanjutnya adalah memprediksi nilai Ekspor provinsi Jawa Tengah serta untuk periode 12 bulan ke depan. Hasil prediksi nilai Ekspor Total Provinsi Jawa Tengah ditampilkan pada Gambar 4.18 dan Gambar 4.19 serta pada Tabel 4.15.



Gambar 4.18. Peramalan Nilai Ekspor Jawa Tengah 12 periode ke depan



Gambar 4.19. Peramalan Nilai Ekspor Jawa Tengah Komoditas 7 untuk 12 periode ke depan

Berdasarkan Gambar 4.18 dan Gambar 4.19 garis biru adalah nilai ekspor aktual dan garis merah adalah hasil prediksi 12 periode ke depan yaitu Januari 2016 sampai Desember 2016 beserta batas bawah dan batas atas prediksi.

Tabel 4.15. Peramalan Nilai Ekspor Total (level 1) dan Komoditas 7 (Level 1)

Tahun	Bulan	t	Ekspor Total (Level 0)		Komoditas 7 (Level 1)	
			<i>Actual</i>	<i>Forecast</i>	<i>Actual</i>	<i>Forecast</i>
2015	Januari	97	427,03	447,91	6,63	6,71
	Februari	98	428,30	444,60	7,25	6,83
	Maret	99	487,62	442,37	7,98	7,94
	April	100	490,77	457,88	8,29	7,40
	Mei	101	461,01	468,43	7,28	7,85
	Juni	102	507,18	471,46	10,29	7,62
	Juli	103	384,25	481,75	7,12	9,87
	Agustus	104	445,00	449,02	9,07	7,46
	September	105	436,42	451,27	9,52	8,32
	Oktober	106	435,32	450,43	6,57	9,35
	November	107	416,86	437,51	7,19	7,24
	Desember	108	455,28	410,66	6,70	7,16



Tahun	Bulan	t	Ekspor Total (Level 0)		Komoditas 7 (Level 1)	
			<i>Actual</i>	<i>Forecast</i>	<i>Actual</i>	<i>Forecast</i>
2016	Januari	109	*	445,11	*	7,02
	Februari	110	*	445,55	*	6,99
	Maret	111	*	445,71	*	6,76
	April	112	*	446,55	*	7,51
	Mei	113	*	448,40	*	6,58
	Juni	114	*	448,90	*	7,30
	Juli	115	*	442,18	*	7,18
	Agustus	116	*	445,20	*	6,54
	September	117	*	446,58	*	6,88
	Oktober	118	*	445,01	*	6,66
	November	119	*	444,75	*	6,80
	Desember	120	*	447,10	*	6,75



Halaman ini sengaja dikosongkan


## LAMPIRAN

Lampiran 1. Data Ekspor


Tahun	Bulan	Komoditas (Juta US\$)																			Jumlah
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	
2007	Januari	5,54	2,48	1,00	4,38	48,91	4,29	5,06	1,62	39,83	2,65	109,82	1,67	14,58	1,15	10,69	0,00	0,83	58,39	0,08	312,97
	Februari	6,55	2,37	0,00	4,34	21,70	4,77	5,63	1,93	35,02	2,56	102,45	1,57	3,06	1,86	10,33	0,02	0,91	61,10	0,09	266,26
	Maret	6,69	2,55	0,00	3,29	46,81	6,75	7,94	2,04	36,10	3,16	113,52	1,54	3,52	1,44	11,56	0,01	0,86	69,04	0,11	316,94
	April	7,72	2,00	5,41	2,99	15,33	3,53	6,78	0,93	36,66	2,95	104,08	1,22	3,48	1,11	8,57	0,02	1,25	62,93	0,10	267,06
	Mei	6,86	2,04	11,49	3,78	29,27	5,96	7,14	2,00	36,80	3,49	115,86	1,38	4,31	4,65	12,66	0,00	1,18	63,50	0,10	312,47
	Juni	7,07	2,33	0,03	4,48	13,18	4,98	7,78	1,76	34,19	3,25	103,89	1,73	4,44	1,01	9,19	0,02	1,19	54,74	0,05	255,31
	Juli	7,12	2,61	7,56	3,87	31,60	5,71	5,75	0,88	31,58	3,20	114,77	2,09	5,49	2,03	10,40	0,00	1,25	53,70	0,13	289,74
	Agustus	5,38	3,83	0,08	3,99	38,50	5,63	7,32	1,93	34,42	5,41	123,29	1,19	5,13	1,53	11,55	0,01	1,59	53,24	0,06	304,08
	September	5,62	3,86	5,72	4,68	55,85	5,89	10,00	1,80	29,53	3,84	113,64	1,32	5,67	1,43	13,46	0,37	1,55	50,36	0,07	314,66
	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
2015	April	6,33	6,72	12,63	16,80	21,22	16,12	8,29	3,05	95,59	2,95	196,01	3,76	4,18	2,74	26,94	0,04	2,61	64,74	0,05	490,77
	Mei	4,37	5,01	9,60	14,47	15,65	12,42	7,28	2,35	87,15	4,27	204,58	3,27	3,67	2,48	24,88	0,05	3,47	55,99	0,05	461,02
	Juni	5,83	6,14	16,46	16,52	13,91	17,94	10,29	2,29	91,88	3,75	221,19	4,16	5,16	1,83	26,83	0,04	3,11	59,81	0,04	507,18
	Juli	6,61	4,77	15,35	12,25	1,99	12,47	7,12	2,29	68,11	2,72	172,07	2,37	3,65	1,77	19,67	0,01	3,36	47,66	0,02	384,25
	Agustus	4,81	7,30	17,75	14,80	3,57	11,36	9,07	1,89	91,05	3,38	188,35	2,61	6,03	2,19	23,56	0,08	4,38	52,80	0,02	445,00
	September	6,22	6,36	9,88	14,96	0,98	13,38	9,52	4,66	90,66	5,35	181,89	3,30	5,61	2,18	22,53	0,04	3,80	55,06	0,04	436,42
	Oktober	7,13	8,25	9,16	14,56	12,41	18,40	6,57	3,39	86,59	3,26	167,16	3,02	4,30	2,15	25,55	0,15	4,39	58,83	0,05	435,32
	Nopember	7,00	6,94	9,90	14,31	6,62	15,07	7,19	2,74	74,43	2,85	180,23	3,08	4,09	1,54	19,79	0,03	3,54	57,47	0,04	416,86
	Desember	3,84	5,37	12,13	17,69	5,22	17,68	6,70	2,50	74,63	3,87	212,20	2,45	3,99	2,10	22,66	0,06	2,72	59,43	0,04	455,28

## Lampiran 2. Time Series Plot Masing-masing Nilai Ekspor


### 1. Binatang Hidup, Produk Hewani




### 2. Produk Nabati




3. Minyak dan lemak hewani taua nabati dan produk disosiasinya




4. Bahan makan olahan, minuman, minuman keras, dan cuka




## 5. Produk mineral




## 6. Produk kimia dan produksi industri yang ada



7. Plastik dan barang palstik, karet dan barang dari karet




8. Jangat dan kulit mentah, kulit samak, kulit berbulu dan barangnya, barang untuk bepergian, tas tangan dan tempat simpan semacamnya, barang dari usus (selain usus ulat sutera)







9. Kayu dan barang dari kayu, arang kayu, gabus dan barang dari gabus, barang dari jerami, rumput esparto atau dari bahan anyaman lainnya, keranjang dan barang anyaman




10. Pulp dari kayu atau bahan selulosa berserat lainnya, kertas atau kertas karton (bekas dan sisa) yang diperoleh kembali, kertas dan kertas karton dan barangnya




## 11. Tekstil dan barang tekstil




## 12. Alas kai, tutup kepala, payung, payung panas, tongkat jalan, tongkat duduk, cambuk, pecut dan sebagainya, bulu unggas olahan dan barangnya, bunga tiruan, barang dari rambut manusia




13. Barang dari batu, gips, semen, asbes, mika atau dari bahan semacam itu, produk keramik, kaca dan barang dari kaca




14. Logam tidak mulia dan barang dari logam tidak mulia




15. Mesin dan pesawat mekanik, perlengkapan listrik, bagiannya, pesawat perekam dan pesawat reproduksi suara, pesawat perekam atau reproduksi suata dan gambar untuk televisi, dan bagian serta perelengkapan dan barang yang semacam itu




16. Kendaraan, pesawat terbang, kendaraan air, dan perlengkapan pengangkutan yang berkaitan




17. Alat dan aparat optik, fotografi, sinematografi, ukur, peneliti, presisi, kedokteran dan bedah, lonceng dan arloji, instrumen musik, bagian dan perlengkapannya




18. Berbagai macam barang hasil pabrik



### 19. Hasil karya seni, barang kegemaran kaum pengumpul dan barang antik



### 20. Ekspor Keseluruhan



### Lampiran 3. Sintaks Pemodelan ARIMA (Komoditas 1) $h=12$

```
data ekspor;  
    input x1 @@;  
datalines;  
2.3537  
2.5593  
2.5865  
2.7785  
2.6192  
2.6589  
.  
.  
.  
.  
2.0857  
3.0315  
2.6926  
2.3958  
2.4104  
2.3896  
2.6777  
2.6571  
;  
proc arima data=ekspor;  
  
/*--- Estimate-----*/  
  
    identify var=x1(1) ;  
    run;  
  
    estimate q=1 noconstant;  
    run;  
  
    forecast lead=12 printall;  
    run;
```

#### Lampiran 4. Sintaks Pemodelan RBFNN (Komoditas 1) $h=12$

```
function RBF1
clc;
data=xlsread('data.xls');
n=length(data);
%-----Forecast-----
kk=1;
ey=7;
%-----12 Step-----
t=data(1:n-12, kk); %menentukan data yang digunakan
p=[lagmatrix(t,1) lagmatrix(t,2)]; %membuat input
p=(p(3:n-12, :)); %menentukan input
t=(t(3:n-12, 1)); %menentukan target
%-----Kluster-----
rng(0);
[idx, c]=kmeans(p, 6);
m=[ (mean(p(idx==1, 1))) (mean(p(idx==1, 2)))
    (mean(p(idx==2, 1))) (mean(p(idx==2, 2)))
    (mean(p(idx==3, 1))) (mean(p(idx==3, 2)))
    (mean(p(idx==4, 1))) (mean(p(idx==4, 2)))
    (mean(p(idx==5, 1))) (mean(p(idx==5, 2)))
    (mean(p(idx==6, 1))) (mean(p(idx==6, 2))) ];
SD=[ (var(p(idx==1)))
    (var(p(idx==2)))
    (var(p(idx==3)))
    (var(p(idx==4)))
    (var(p(idx==5)))
    (var(p(idx==6))) ];
%-----RBF-----
H=rbfDesign(transpose(p), transpose(m), transpose(SD), 'b');
lambda=globalRidge(H, t, 0.05);
w=inv(transpose(H)*H+lambda*eye(ey))*transpose(H)*t;

ph(1)=t(93); %initial value
ph(2)=t(94); %initial value
for i=3:14 %periode yang akan diprediksi
    ph(i)=(w(1, :)*(exp(((ph(i-1)-(mean(p(idx==1, 1))))/SD(1))^2/(-2)))+((ph(i-2)-(mean(p(idx==1, 2))))/SD(1))^2/(-2)))+...
    (w(2, :)*(exp(((ph(i-1)-(mean(p(idx==2, 1))))/SD(2))^2/(-2)))+((ph(i-2)-(mean(p(idx==2, 2))))/SD(2))^2/(-2)))+...
    (w(3, :)*(exp(((ph(i-1)-(mean(p(idx==3, 1))))/SD(3))^2/(-2)))+((ph(i-2)-(mean(p(idx==3, 2))))/SD(3))^2/(-2)))+...
    (w(4, :)*(exp(((ph(i-1)-(mean(p(idx==4, 1))))/SD(4))^2/(-2)))+((ph(i-2)-(mean(p(idx==4, 2))))/SD(4))^2/(-2)))+...
    (w(5, :)*(exp(((ph(i-1)-(mean(p(idx==5, 1))))/SD(5))^2/(-2)))+((ph(i-2)-(mean(p(idx==5, 2))))/SD(5))^2/(-2)))+...
    (w(6, :)*(exp(((ph(i-1)-(mean(p(idx==6, 1))))/SD(6))^2/(-2)))+((ph(i-2)-(mean(p(idx==6, 2))))/SD(6))^2/(-2)))+w(7, :);
end
k1=transpose(ph(3:14));
kom1=table(k1);
kom1(1:12, :);
filename = 'RBF_Hierarchy.xlsx';
writetable(kom1, filename, 'Sheet', 1, 'Range', 'A1'); %peletakan hasil
```



## Lampiran 5. Sintaks Pemodelan Hybrid ARIMA-RBFNN (Komoditas 1) $h=12$

```
function Hybrid1
clc;
%-----Forecast-----
ff=1; kk=2; ey=4;
%-----12 Step-----
namafile='datakompli.xls';
sheet=1;
data=xlsread(namafile,sheet);
n=length(data);
t=data(1:n-12,kk); %menentukan data yang digunakan
farima=data(96:107,ff);
p=[lagmatrix(t,1) lagmatrix(t,2)]; %membuat input
p=p(3:n-12,:); %menentukan input
t=t(3:n-12,1); %menentukan target
%-----Kluster-----
rng(0);
[idx,c]=kmeans(p,6);
m=[(mean(p(idx==1,1))) (mean(p(idx==1,2)))
    (mean(p(idx==2,1))) (mean(p(idx==2,2)))
    (mean(p(idx==3,1))) (mean(p(idx==3,2)))
    (mean(p(idx==4,1))) (mean(p(idx==4,2)))
    (mean(p(idx==5,1))) (mean(p(idx==5,2)))
    (mean(p(idx==6,1))) (mean(p(idx==6,2)))];
SD=[(var(p(idx==1)))
    (var(p(idx==2)))
    (var(p(idx==3)))
    (var(p(idx==4)))
    (var(p(idx==5)))
    (var(p(idx==6)))];
%-----RBF-----
H=rbfDesign(transpose(p),transpose(m),transpose(SD),'b');
lambda=globalRidge(H,t,0.05);
w=inv(transpose(H)*H+lambda*eye(ey))*transpose(H)*t;
ph(1)=t(92); %initial value
ph(2)=t(93); %initial value
for i=3:14 %periode yang akan diprediksi
ph(i)=(w(1,:)*(exp(((ph(i-1)-(mean(p(idx==1,1))))/SD(1))^2/(-2))+((ph(i-2)-(mean(p(idx==1,2))))/SD(1))^2/(-2))))+...
    (w(2,:)*(exp(((ph(i-1)-(mean(p(idx==2,1))))/SD(2))^2/(-2))+((ph(i-2)-(mean(p(idx==2,2))))/SD(2))^2/(-2))))+...
    (w(3,:)*(exp(((ph(i-1)-(mean(p(idx==3,1))))/SD(3))^2/(-2))+((ph(i-2)-(mean(p(idx==3,2))))/SD(3))^2/(-2))))+...
    (w(4,:)*(exp(((ph(i-1)-(mean(p(idx==4,1))))/SD(4))^2/(-2))+((ph(i-2)-(mean(p(idx==4,2))))/SD(4))^2/(-2))))+...
    (w(5,:)*(exp(((ph(i-1)-(mean(p(idx==5,1))))/SD(5))^2/(-2))+((ph(i-2)-(mean(p(idx==5,2))))/SD(5))^2/(-2))))+...
    (w(6,:)*(exp(((ph(i-1)-(mean(p(idx==6,1))))/SD(6))^2/(-2))+((ph(i-2)-(mean(p(idx==6,2))))/SD(6))^2/(-2))))+w(7,:);
end
k1=transpose(ph(3:14));
k1=k1+farima;
koml=table(k1);
koml(1:12,:);
filename = 'RBF_Hierarchy.xlsx';
writetable(koml,filename,'Sheet',1,'Range','A1'); %peletakan hasil
```

Lampiran 6. Hasil Keseluruhan Pemilihan Model

Hasil *Origin Rolling Forecast* dengan pemodelan ARIMA

		Forecast Horizon ( <i>h</i> )											
		1	2	3	4	5	6	7	8	9	10	11	12
MdAPE	Level 0 (1 series)												
	Bottom-up	4,82	6,32	7,88	6,45	6,83	7,34	3,14	0,39	1,25	4,00	5,80	1,80
	Independent	5,13	5,20	7,38	8,50	9,65	11,56	5,58	1,70	2,71	5,25	5,61	1,49
	Level 1 (19 series)												
	Independent	17,36	19,28	19,77	21,57	24,51	27,05	26,30	25,52	25,01	22,45	25,09	23,11
	Top-down HP1	35,51	35,17	38,56	42,79	48,22	56,18	57,02	50,80	47,36	39,90	49,96	50,11
	Top-down HP2	35,68	35,27	38,73	42,93	48,59	56,52	57,60	51,60	47,80	40,35	50,25	50,46
	Top-down FP	18,02	20,91	20,07	21,82	24,97	27,97	27,07	26,36	26,11	22,05	24,85	23,36
sMAPE		Forecast Horizon ( <i>h</i> )											
		1	2	3	4	5	6	7	8	9	10	11	12
	Level 0 (1 series)												
	Bottom-up	6,15	6,58	7,87	8,25	7,87	8,03	6,12	2,71	2,04	4,16	5,67	1,82
	Independent	6,73	7,50	8,50	9,73	9,64	9,81	7,62	4,47	2,33	4,76	5,50	1,51
	Level 1 (19 series)												
	Independent	21,74	23,83	23,78	24,56	25,00	25,22	25,45	26,02	25,35	22,53	21,22	20,15
	Top-down HP1	28,88	29,00	28,53	29,44	30,04	30,96	31,89	30,70	30,15	27,60	29,39	29,15
	Top-down HP2	28,88	29,01	28,52	29,44	30,05	30,96	31,94	30,77	30,18	27,65	29,36	28,95
	Top-down FP	22,10	24,33	24,02	25,06	25,00	25,44	25,80	26,69	25,65	22,16	21,10	20,32

		Forecast Horizon ( $h$ )											
		1	2	3	4	5	6	7	8	9	10	11	12
sMdAPE	Level 0 (1 series)												
	Bottom-up	4,86	6,52	7,93	6,25	6,61	7,08	3,09	0,39	1,24	4,08	5,67	1,82
	Independent	5,17	5,22	7,66	8,88	9,25	11,79	5,40	1,71	2,67	5,12	5,50	1,51
	Level 1 (19 series)												
	Independent	17,51	19,95	21,09	22,12	22,73	22,59	21,38	24,04	23,18	23,02	21,22	20,15
	Top-down HP1	26,05	26,44	27,31	27,74	28,60	30,66	29,09	27,95	29,03	26,27	29,39	29,15
	Top-down HP2	26,04	26,44	27,33	27,80	28,53	30,52	28,97	28,11	29,04	26,27	29,36	28,95
	Top-down FP	18,24	21,48	21,61	22,57	22,89	23,68	21,87	24,84	24,08	22,53	21,10	20,32

Hasil *Origin Rolling Forecast* dengan pemodelan RBFNN

		Forecast Horizon ( $h$ )											
		1	2	3	4	5	6	7	8	9	10	11	12
MdAPE	Level 0 (1 series)												
	Bottom-up	5,28	4,96	4,17	4,13	3,67	4,89	2,71	2,51	3,07	5,33	6,87	0,91
	Independent	8,41	8,86	11,64	9,80	9,19	7,71	8,40	11,56	12,03	12,15	12,22	16,03
	Level 1 (19 series)												
	Independent	35,82	38,48	45,84	41,91	45,33	50,97	51,54	52,56	51,05	42,38	55,14	53,99
	Top-down HP1	33,01	31,39	36,11	39,58	41,42	45,92	48,68	44,85	43,28	37,70	42,64	42,07
	Top-down HP2	33,20	31,66	36,28	39,79	41,93	46,43	49,31	45,55	43,67	38,00	42,93	42,50
	Top-down FP	31,39	35,98	42,02	37,87	40,12	45,57	45,56	49,07	44,60	36,37	42,93	40,63

		Forecast Horizon ( $h$ )											
		1	2	3	4	5	6	7	8	9	10	11	12
sMAPE	Level 0 (1 series)												
	Bottom-up	7,39	6,15	6,29	6,37	5,41	6,24	5,23	3,03	3,06	4,79	6,66	0,91
	Independent	9,75	10,86	13,01	13,01	12,47	10,12	8,45	10,72	10,96	11,88	13,11	17,43
	Level 1 (19 series)												
	Independent	30,35	32,46	33,24	33,85	33,48	34,32	35,77	34,51	34,26	31,31	36,22	37,29
	Top-down HP1	28,40	28,78	29,01	30,30	30,79	31,18	31,57	31,84	32,01	29,48	29,42	28,87
	Top-down HP2	28,43	28,78	29,06	30,39	30,91	31,29	31,70	31,93	32,09	29,60	29,42	28,82
	Top-down FP	29,69	32,02	33,43	33,78	33,21	33,59	34,87	35,74	34,69	30,18	32,46	33,07
sMdAPE		Forecast Horizon ( $h$ )											
		1	2	3	4	5	6	7	8	9	10	11	12
	Level 0 (1 series)												
	Bottom-up	5,27	4,84	4,18	4,22	3,60	5,01	2,68	2,54	3,00	5,19	6,66	0,91
	Independent	8,81	9,27	12,37	10,31	9,63	8,02	8,78	12,27	12,80	12,93	13,11	17,43
	Level 1 (19 series)												
	Independet	28,00	29,51	32,20	30,62	31,00	31,22	32,62	34,11	34,23	32,50	36,22	37,29
	Top-down HP1	25,98	25,88	27,73	29,35	28,89	29,11	29,14	30,60	31,12	29,72	29,42	28,87
	Top-down HP2	26,18	25,97	27,91	29,32	29,11	29,25	29,35	31,08	31,29	29,97	29,42	28,82
	Top-down FP	26,03	30,41	33,17	30,69	30,88	32,09	32,43	36,24	34,35	31,68	32,46	33,07

Hasil *Origin Rolling Forecast* dengan pemodelan *Hybrid ARIMA-RBFNN*

		Forecast Horizon ( <i>h</i> )											
		1	2	3	4	5	6	7	8	9	10	11	12
MdAPE	Level 0 (1 series)												
	Bottom-up	4,29	5,33	7,75	7,82	8,23	8,61	4,28	1,33	1,97	3,37	5,58	0,54
	Independent	4,97	4,48	7,44	8,99	9,26	11,89	5,65	2,25	2,13	4,30	5,74	2,04
	Level 1 (19 series)												
	Independent	19,59	21,10	21,78	23,28	25,40	28,83	26,35	23,32	25,34	21,38	26,04	23,92
	Top-down HP1	35,50	34,81	38,16	42,37	47,94	56,34	56,66	50,63	47,24	39,65	49,41	49,63
	Top-down HP2	35,68	34,91	38,33	42,61	48,29	56,70	57,21	51,43	47,71	40,10	49,71	49,98
	Top-down FP	19,50	21,64	22,29	23,47	25,48	29,27	26,15	24,00	26,48	20,56	25,31	23,09
sMAPE		Forecast Horizon ( <i>h</i> )											
		1	2	3	4	5	6	7	8	9	10	11	12
	Level 0 (1 series)												
	Bottom-up	6,28	6,78	8,18	8,59	8,20	8,61	6,80	3,54	1,88	4,39	5,43	0,54
	Independent	6,31	7,31	8,55	10,03	9,77	9,81	7,69	4,39	1,97	4,46	5,68	2,06
	Level 1 (19 series)												
	Independent	21,81	24,70	25,02	24,98	25,64	26,27	25,38	25,61	25,92	23,02	21,56	20,62
	Top-down HP1	28,79	28,95	28,49	29,47	30,04	30,93	31,81	30,79	30,19	27,54	29,23	28,97
	Top-down HP2	28,80	28,94	28,50	29,47	30,05	30,93	31,87	30,86	30,24	27,58	29,22	28,77
	Top-down FP	21,93	24,99	25,29	25,52	25,46	26,30	25,25	26,19	26,34	22,61	21,24	20,17

		Forecast Horizon ( $h$ )											
		1	2	3	4	5	6	7	8	9	10	11	12
sMdAPE	Level 0 (1 series)												
	Bottom-up	4,32	5,35	7,72	7,53	7,91	8,26	4,19	1,32	1,95	3,43	5,43	0,54
	Independent	4,85	4,38	7,73	9,04	9,14	11,22	5,46	2,27	2,11	4,21	5,68	2,06
	Level 1 (19 series)												
	Independent	19,15	21,71	23,48	24,62	24,33	23,63	21,76	23,79	24,43	20,97	21,56	20,62
	Top-down HP1	26,02	26,19	27,26	27,64	28,49	30,80	29,07	27,97	29,06	26,33	29,23	28,97
	Top-down HP2	26,03	26,21	27,31	27,73	28,45	30,66	28,93	28,14	29,12	26,34	29,22	28,77
	Top-down FP	19,27	22,55	23,81	25,22	24,79	24,31	21,64	24,53	25,20	20,65	21,24	20,17

Halaman ini sengaja dikosongkan





## **BAB V**

### **KESIMPULAN**

#### **5.1. Kesimpulan**

Berdasarkan hasil dan pembahasan, maka diperoleh beberapa kesimpulan yaitu

- Untuk data Nilai Ekspor Jawa Tengah (level 0) pendekatan prediksi *Bottom-up* dengan pemodelan *Hybrid* ARIMA-RBFNN dapat digunakan untuk prediksi jangka panjang. Sedangkan pendekatan prediksi *Bottom-up* dengan pemodelan RBFNN dapat digunakan untuk prediksi jangka pendek maupun menengah. Pada level 1 yaitu Nilai Ekspor Komoditas, pendekatan prediksi *independent* (tanpa hirarki) dengan pemodelan ARIMA dapat digunakan untuk prediksi jangka pendek, menengah maupun jangka panjang.
- Dengan kriteria kebaikan MdAPE, sMAPE dan sMdAPE yang ditampilkan pada Lampiran 6. Diperoleh kesimpulan bahwa tingkat keakuratan masing-masing pendekatan untuk masing-masing pemodelan memiliki nilai dengan selisih yang relatif kecil untuk masing-masing *Forecast Horizon* (h).
- Hasil prediksi nilai ekspor total (level 0) untuk periode 12 bulan ke depan dapat dilihat pada Gambar 4.18 dan Tabel 15. Hasil prediksi yang dihasilkan membentuk pola yang cenderung konstan serta mengalami sedikit penurunan pada bulan Juli 2016.

#### **5.2. Saran**

Diharapkan pada penelitian ke depan, *Hierarchical Time series* dengan pendekatan lain dapat digunakan untuk data dengan struktur hirarki pada berbagai macam aspek, seperti aspek sosial maupun budaya.

Halaman ini sengaja dikosongkan

## DAFTAR PUSTAKA

- Armstrong, J. Scoot. & Collopy, Fred. (1992). Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons. *International Journal of Forecasting*, Vol. 8, Page 69-80.
- Athanasopoulos, George., Ahmed, Roman A. & Hyndman, Rob J. (2007). Hierarchical Forecasting for Australian Domestic Tourism. Monash University.
- Chalid, Nursiah. (2011). Peranan Ekspor dalam Perekonomian Indonesia. *Jurnal Ekonomi*. Vol.19, No 1.
- Cryer, Jonathan D. & Chan, Kung-Sik. (2008). *Time Series Analysis with Applications in R*. Iowa City, Iowa: Springer.
- Goojier, Jan G De. & Hyndman, Rob J. (2006). 25 Years of Time Series Forecasting.
- Hanrahan, Grady. (2011). *Artificial Neural Networks in Biological and Environmental Analysis*. London, New York: CRC Press.
- Hyndman, Rob J. & Koehler, B. Anne. (2005). Another Look at Measures of Forecast Accuracy. Monash University.
- Johnson, R. A. & Winchurn, DW. (2007). *Applied Multivariate Statistical Analysis*, 6th ed. Upper Sadler River, New Jersey: Pearson.
- Makridakis, Spyros., Wheelright, Steven, C., & McGee, Victor, C. (1999). *Metode dan Aplikasi Peramalan*. Jakarta: Binarupa Aksara.

- Makridakis, Spyros., & Hibon, Michele. (2000). The M3-Competition: Result Conclusions and Implications. *International Journal of Forecasting*. Vol. 16, Page. 451-476.
- Mahkya, Dani Al. (2014). Aplikasi Metode Golden Section untuk Optimasi Parameter pada Metode Exponential Smoothing. *Jurnal Gaussian*, Vol.3, No 4, hlm. 605-614.
- McNelis, Paul, D. (2005). *Neural Network in Finance Gaining Predictive Edge in the Market*. San Diego, California: Elsevier.
- Montgomery, Douglas C., Jennings, Cheryl., & Kulachi, Murat. (2008). *Introduction to Time Series Analysis and Forecasting*. Hoboken, New Jersey: Willey.
- Morgan, L. & Kourentzes, N. (2015). Forecasting in Hierarchical Model. Lancaster University.
- Orr, Mark. J. L. (1996). Introduction to Radial Basis Function Neural Network. Edinburgh: University of Edinburgh.
- Prayoga, I. G. S. A., Suhartono., & Rahayu, S.P. (2015). Hierarchical Forecasting Method Based on ARIMAX and Recurrent Neural Network for Motorcycle Sales Prediction. *International Journal of Applied Mathematics and Statistics*. Vol. 53, No. 5.
- Shang, Lin Han. & Smith, Peter W.F. (2013). Grouped Time-Series Forecasting with an Application to Regional Infant Mortality Counts. *Centre for Population Change Working Paper*. Number 40.
- Smith, Kate., Gupta, Jatinder. (2002). *Neural Network in Business: Techniques and Applications*. United States of America: Idea Group Publishing.

- Sturgil, Derek. (2009). *Variable Shape Parameter Strategies in Radial Basis Function Methods*. Huntington, West Virginia: Marshall University.
- Rejekiingsih, Tri Wahyu. (2012). Konsentrasi Ekspor Provinsi Jawa Tengah. *Jurnal Ekonomi Kuantitatif Terapan*. Vol.5, hlm. 109-118.
- Tambun, Nikita., Palar, Sutomo dan Rompas, Wensy. (2014). Analisis Struktur dan Kinerja Ekspor Komoditas Pertanian Pasca Krisis Ekonomi di Sulawesi Utara. *Jurnal Berkala Ilmiah Efisiensi*, Vol 14, No.3, hlm. 82-93.
- Utari, Pranita Dian dan Suhartono. (2011). Prediksi Permintaan BBM di PT. Pertamina Region V dengan Metode Peramalan Data Time Series Hirarki. Institut Teknologi Sepuluh Nopember.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Method. Second Edition*. New York: Pearson Education.
- Zhang, G. Peter. (2003). Time Series Forecasting using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. Vol. 50, Page 159-175.
- Zeng, Zhigang., Wang, Jun. (2010). *Advances in Neural Network Research and Applications*. Berlin: Springer.

Halaman ini sengaja dikosongkan

## BIODATA PENULIS



Penulis lahir pada 4 Februari 1993 dari pasangan Purwanto dan Titik Utami di sebuah desa bernama Utama Jaya, dengan nama lengkap Dani Al Mahkya. Utama Jaya adalah sebuah desa yang terletak di kecamatan Seputih Mataram, kabupaten Lampung Tengah, propinsi Lampung. Penulis merupakan anak pertama dari dua bersaudara. Dengan saudara laki-laki bernama Prana Al Mahkya. Kedua orang tua selalu memberikan semangat, motivasi serta do'a yang akhirnya membawa penulis menyelesaikan studi Magister di Jurusan Statistika, Institut Teknologi Sepuluh Nopember. Sebelum mencapai tahapan ini, penulis telah melalui tahapan-tahapan yang panjang. Penulis menempuh pendidikan Sekolah Dasar di SD Negeri 2 Utama Jaya saat berusia 5 tahun 5 bulan dan menyelesaikannya pada tahun 2004. Pada tahun 2007 penulis menyelesaikan pendidikan Sekolah Menengah Pertama di SMP Negeri 2 Seputih Mataram. Dan pada tahun 2010 penulis menyelesaikan pendidikan Sekolah Menengah Atas di SMA Negeri 1 Kotagajah, Lampung tengah. Pada tahun 2010 berbekal semangat, motivasi serta do'a kedua orang tua, penulis merantau ke pulau Jawa untuk mengenyam pendidikan Sarjana. Dipilihlah Universitas Diponegoro sebagai tempat menuntut ilmu. Pada tahun 2014 penulis berhasil menyelesaikan pendidikan Sarjana. Setelah itu penulis memutuskan untuk melanjutkan studi ke jenjang Magister di Jurusan Statistika, Institut Teknologi Sepuluh Nopember. Setelah menempuh masa studi selama 3 semester, akhirnya penulis menyelesaikan Tugas Akhir Tesis dengan judul Prediksi Nilai Ekspor Jawa Tengah menggunakan Pendekatan Hierarchical Time Series. Penulis berharap Tugas Akhir ini dapat bermanfaat untuk penelitian-penelitian selanjutnya. Penulis sangat mengharapkan kritik, saran ataupun pertanyaan guna menjadikan Tugas Akhir ini lebih baik lagi. Untuk kritik, saran maupun pertanyaan dapat menghubungi penulis melalui email [danialmahkya@gmail.com](mailto:danialmahkya@gmail.com) dan nomor telepon 085784476274.